PATENT ABSTRACTS OF JAPAN

(11)Publication number:

11-316654

(43) Date of publication of application: 16.11.1999

(51)Int.Cl.

G06F 3/06 G06F 3/06

G11B 20/10

(21)Application number: 11-056601

(71)Applicant: HITACHI LTD

HITACHI COMPUT ENG CORP LTD

(22)Date of filing:

04.03.1999

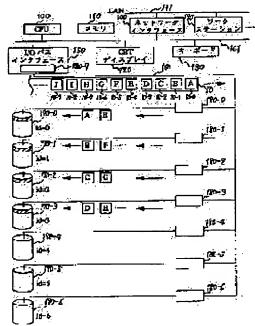
(72)Inventor: AKISAWA MITSURU

KATO KANJI

SUZUKI HIROYOSHI MAKI TOSHIYUKI

(54) DATA ACCESS CONTROL METHOD, COMPUTER SYSTEM AND DISK ARRAY SYSTEM (57)Abstract:

PROBLEM TO BE SOLVED: To attain parallel operations of magnetic disk devices and also to attain a fast file access by dividing a file and performing the write and read operations to the different magnetic disk devices. SOLUTION: In a file read mode, a file 10 stored in a memory 110 is divided and stored in four magnetic disk devices 170-0 to 170-3 (id=0 to 3) with a single data block defined as an I/O unit, for example. Then a data block A10-0 is written into the device 170-0 (id=0). When the block A10-0 is written into an internal cache of the device 170-0, the next data block B10-1 is written into the device 170-1 (id=1) without waiting for the completion of write of the block A10-0 into a disk medium from an internal cache. Thus, the next write request is issued before a write operation is carried out from an internal cache to a disk medium.



LEGAL STATUS

[Date of request for examination]

04.03.1999

[Date of sending the examiner's decision of

rejection] [Kind of final disposal of application other than

the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number] 3387017 [Date of registration] 10.01.2003

[Number of appeal against examiner's decision

of rejection]
[Date of requesting appeal against examiner's decision of rejection]
[Date of extinction of right]

(19) 日本国特許庁 (JP)

(12) 公開特許公報(A)

(11)特許出願公開番号

特開平11-316654

(43)公開日 平成11年(1999)11月16日

	(51) Int.Cl. ⁶		識別記号	FΙ		
-	G06F	3/06	302	G06F	3/06	302D
			5 4 0			5 4 0
•	G11B	20/10		G11B	20/10	Н

審査請求 有 請求項の数27 OL (全 36 頁)

(21)出願番号	特願平11-56601	(71) 出願人	000005108
(62)分割の表示	特願平4-46685の分割		株式会社日立製作所
(22)出願日	平成4年(1992)3月4日		東京都千代田区神田駿河台四丁目6番地
		(71)出願人	000233011
	•		日立コンピュータエンジニアリング株式会
			社
			神奈川県秦野市堀山下1番地
		(72)発明者	秋沢 充
			神奈川県川崎市幸区鹿島田890番地株式会
			社日立製作所システム開発本部内
		(74)代理人	弁理士 小川 勝男
			最終頁に続く

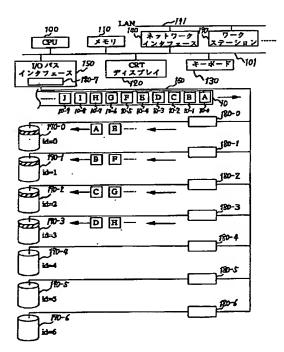
(54) 【発明の名称】 データアクセス制御方法および計算機システム並びにディスクアレイシステム

(57) 【要約】

【目的】本発明の目的は、極めて低コストで高速なファイルアクセスが可能な計算機システムを提供することにある。

【構成】ディスコネクト・リコネクト機能付き I / Oバスとのインタフェースを有する計算機システム、および I / Oバスに接続された複数の磁気ディスク装置から構成される。計算機システムは、ディスク管理情報、ファイル管理情報、およびファイル記述子対応情報を参照して、ディスクアクセスの際にファイルを分割して複数のディスクに非同期で読み書きするための制御手段を有する。

【効果】複数の磁気ディスク装置のみで他の特別な制御 装置を用いずに、高速なファイルアクセスを実現するこ とができるという効果がある。特殊なハードウェアを必 要としないので、従来よりも非常に低コストで高速なファイルアクセスが可能な計算機システムを実現できる。 图1



【特許請求の範囲】

【請求項1】データを複数に分割した第1の分割データ 群を複数の記憶装置のそれぞれに分配して格納し、上記 データを複数に分割した第2の分割データ群を複数の記 憶装置のそれぞれに分配して格納し、上記第1の分割デ ータが壊れた場合は、上記壊れた第1の分割データに対 なする上記第2の分割データを用いて上記第1の分割デ ータを修復することを特徴とするデータアクセス制御方 ・法。

【請求項2】データを複数に分割した第1の分割データ 群を複数の記憶装置にそれぞれに格納し、上記データを 複数に分割した第2の分割データ群を複数の記憶装置の それぞれに格納し、上記第1の分割データをアクセスす る際に、上記第1の分割データが壊れたことを検出した 場合は、上記壊れた第1の分割データに対応する上記第 2の分割データをアクセスすることを特徴とするデータ アクセス制御方法。

【請求項3】データを複数に分割した第1の分割データ群を複数の記憶装置にそれぞれに格納し、上記データを複数に分割した第2の分割データ群を複数の記憶装置にそれぞれに格納し、新たなデータを追加する際には、上記新たなデータを複数に分割して上記第1の分割データ群を格納した複数の記憶装置のそれぞれに格納し、上記新たなデータを複数に分割して上記第2の分割データ群を格納した複数の記憶装置のそれぞれに格納することを特徴とするデータアクセス制御方法。

【請求項4】データを複数に分割した第1の分割データ群を複数の記憶装置にそれぞれに格納し、上記データを複数に分割した第2の分割データ群を複数の記憶装置にそれぞれに格納し、上記分割されたデータを削除する際には、上記第1の分割データ群を格納した複数の記憶装置に格納されている削除対象の上記分割されたデータを削除し、上記第2の分割データ群を格納した複数の記憶装置に格納されている削除対象の上記分割されたデータを削除することを特徴とするデータアクセス制御方法。

【請求項5】データを複数に分割した第1の分割データ 群を複数の記憶装置にそれぞれに格納し、上記データを 複数に分割した第2の分割データ群を複数の記憶装置に それぞれに格納し、上記分割されたデータを更新する際 には、上記第1の分割データ群を格納した複数の記憶装 置に格納されている更新対象の上記分割されたデータを 更新し、上記第2の分割データ群を格納した複数の記憶 装置に格納されている更新対象の上記分割されたデータ を更新することを特徴とするデータアクセス制御方法。

【請求項6】データを第1の記憶装置に格納し、上記データを第2の記憶装置に格納し、第1のデータにアクセスする際に、上記第1の記憶装置に格納した上記データが壊れたことを検出した場合、第2の記憶装置に格納している上記データをアクセスするデータアクセス制御方法において、

上記第1の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割し、上記複数の記憶装置の それぞれに、分割されたデータを格納することを特徴と するデータアクセス制御方法。

【請求項7】データを第1の記憶装置に格納し、上記データを第2の記憶装置に格納し、第1のデータにアクセスする際に、上記第1の記憶装置に格納した上記データが壊れたことを検出した場合、第2の記憶装置に格納している上記データをアクセスするデータアクセス制御方法において、

上記第2の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割し、上記複数の記憶装置の それぞれに、分割されたデータを格納することを特徴と するデータアクセス制御方法。

【請求項8】請求項6項のデータアクセス制御方法において、上記第2の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割し、上記複数の記憶装置のそれぞれに、分割されたデータを格納することを特徴とするデータアクセス制御方法。

0 【請求項9】請求項1項から請求項8項のデータアクセス制御方法において、上記記憶装置としてディスク装置を用いることを特徴とするデータアクセス制御方法。

【請求項10】請求項8項のデータアクセス制御方法において、上記第1の記憶装置における複数の記憶装置は、上記第2の記憶装置における複数の記憶装置と同じ記憶装置を用いることを特徴とするデータアクセス制御方法。

【請求項11】データを複数に分割した第1の分割データ群をそれぞれに分配して格納する複数の記憶装置と、の上記データを複数に分割した第2の分割データ群をそれぞれに分配して格納する複数の記憶装置と、上記第1の分割データが破壊された場合は、上記破壊された第1の分割データに対応する上記第2の分割データを用いて上記第1の分割データを修復する制御手段とを備えたことを特徴とする計算機システム。

【請求項12】データを格納する第1の記憶装置と、上記データを格納する第2の記憶装置と、上記データをアクセスする際に、上記第1の記憶装置に格納した上記データが壊れたことを検出した場合、第2の記憶装置に格納している上記データをアクセスする制御手段を備えた計算機システムにおいて、

上記第1の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割する分割手段と、上記複数の記憶装置のそれぞれに上記分割されたデータを格納する格納手段とを備えたことを特徴とする計算機システ

【請求項13】データを格納する第1の記憶装置と、上記データを格納する第2の記憶装置と、上記データをアクセスする際に、上記第1の記憶装置に格納した上記デラのインではある。第2の記憶装置に格

2

納している上記データをアクセスする制御手段を備えた 計算機システムにおいて、

上記第2の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割する分割手段と、上記複数の記憶装置のそれぞれに上記分割されたデータを格納する格納手段とを備えたことを特徴とする計算機システーム。

【請求項14】データをに格納する第1の記憶装置と、上記データを格納する第2の記憶装置と、上記第1の記憶装置に格納した上記データが壊れたことを検出した場合、第2の記憶装置に格納している上記データを用いて上記第1の記憶装置に格納した上記データを修復する制御手段を備えた計算機システムにおいて、

上記第1の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割する分割手段と、上記複数の記憶装置のそれぞれに上記分割されたデータを格納する格納手段とを備えたことを特徴とする計算機システム。

【請求項15】データを格納する第1の記憶装置と、上記データを格納する第2の記憶装置と、上記第1の記憶 20 装置に格納した上記データが壊れたことを検出した場合、第2の記憶装置に格納している上記データを用いて上記第1の記憶装置に格納した上記データを修復する制御手段を備えた計算機システムにおいて、

上記第2の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割する分割手段と、上記複数の記憶装置のそれぞれに上記分割されたデータを格納する格納手段とを備えたことを特徴とする計算機システム。

【請求項16】請求項14項の計算機システムにおいて、上記第2の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割する分割手段と、上記複数の記憶装置のそれぞれに上記分割されたデータを格納する格納手段と、上記第1の記憶装置に格納された上記壊れたデータの壊れた個所と対応する上記第2の記憶装置に格納された分割データを用いて修復する修復手段を備えたことを特徴とする計算機システム。

【請求項17】請求項11項から請求項16項のディスクアレイシステムにおいて、上記記憶装置としてディスク装置を用いることを特徴とする計算機システム。

【請求項18】データを複数に分割した第1の分割データ群をそれぞれに分配して格納する複数の記憶装置と、上記データを複数に分割した第2の分割データ群をそれぞれに分配して格納する複数の記憶装置と、上記第1の分割データが壊れた場合は、上記破壊れた第1の分割データを開いて上記第1の分割データを修復する制御手段とを備えたことを特徴とするディスクアレイシステム。

【請求項19】データを複数に分割した第1の分割デー 夕群をそれぞれに分配して格納する複数の記憶装置と、 上記データを複数に分割した第2の分割データ群をそれ ぞれに分配して格納する複数の記憶装置と、上記第1の 分割データが壊れた場合は、上記壊れた第1の分割デー タに対応する上記第2の分割データをアクセスする制御 手段とを備えたことを特徴とするディスクアレイシステム。

【請求項20】データを複数に分割した第1の分割データ群をそれぞれに分配して格納する複数の記憶装置と、上記データを複数に分割した第2の分割データ群をそれぞれに分配して格納する複数の記憶装置と、新たなデータを追加する際には、上記新たなデータを複数に分割して上記第1の分割データ群を格納した複数の記憶装置のそれぞれに格納し、上記新たなデータを複数に分割して上記第2の分割データ群を格納した複数の記憶装置のそれぞれに格納する制御手段とを備えたことを特徴とするディスクアレイシステム。

【請求項21】データを複数に分割した第1の分割データ群をそれぞれに分配して格納する複数の記憶装置と、上記データを複数に分割した第2の分割データ群をそれぞれに分配して格納する複数の記憶装置と、上記分割されたデータを削除する際には、上記第1の分割データ群を格納した複数の記憶装置に格納されている削除対象の上記分割されたデータを削除し、上記第2の分割データ群を格納した複数の記憶装置に格納されている削除対象の上記分割されたデータを削除する制御手段とを備えたことを特徴とするディスクアレイシステム。

【請求項22】データを複数に分割した第1の分割データ群をそれぞれに分配して格納する複数の記憶装置と、上記データを複数に分割した第2の分割データ群をそれ30 ぞれに分配して格納する複数の記憶装置と、上記分割されたデータを更新する際には、上記第1の分割データ群を格納した複数の記憶装置に格納されている更新対象の上記分割されたデータを更新し、上記第2の分割データ群を格納した複数の記憶装置に格納されている更新対象の上記分割されたデータを更新する制御手段とを備えたことを特徴とするディスクアレイシステム。

【請求項23】データを格納する第1の記憶装置と、上記データを格納する第2の記憶装置と、上記データをアクセスする際に、上記第1の記憶装置に格納した上記データが壊れたことを検出した場合、第2の記憶装置に格納している上記データをアクセスする制御手段を備えたディスクアレイシステムにおいて、

上記第1の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割する分割手段と、上記複数の記憶装置のそれぞれに上記分割されたデータを格納する格納手段とを備えたことを特徴とするディスクアレイシステム。

【請求項24】データを格納する第1の記憶装置と、上記データを格納する第2の記憶装置と、上記データをア 50 クセスする際に、上記第1の記憶装置に格納した上記デ

ータが壊れたことを検出した場合、第2の記憶装置に格納している上記データをアクセスする制御手段を備えた ディスクアレイシステムにおいて、

上記第2の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割する分割手段と、上記複数の記憶装置のそれぞれに上記分割されたデータを格納する格納手段とを備えたことを特徴とするディスクアレイシステム。

- 【請求項25】データをに格納する第1の記憶装置と、 用いることにより、I/Oバスインに記データを格納する第2の記憶装置と、上記第1の記 10 ックの解消も図ろうとしている。 憶装置に格納した上記データを検出した場合、第2の記憶装置に格納している上記データを制いて た図47にファイル読み出しの場合に発出した上記第1の記憶装置に格納した上記データを修復する制 示す。図46及び図47は、各名の手段を備えたディスクアレイシステムにおいて、 クで構成されている例であるが、

上記第1の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割する分割手段と、上記複数の記憶装置のそれぞれに上記分割されたデータを格納する格納手段とを備えたことを特徴とするディスクアレイシステム。

【請求項26】データを格納する第1の記憶装置と、上 20 記データを格納する第2の記憶装置と、上記第1の記憶 装置に格納した上記データが壊れたことを検出した場 合、第2の記憶装置に格納している上記データを用いて 上記第1の記憶装置に格納した上記データを修復する制 御手段を備えたディスクアレイシステムにおいて、

上記第2の記憶装置として複数の記憶装置が存在する場合、上記データを複数に分割する分割手段と、上記複数の記憶装置のそれぞれに上記分割されたデータを格納する格納手段とを備えたことを特徴とするディスクアレイシステム。

【請求項27】請求項18項から請求項26項のディスクアレイシステムにおいて、上記記憶装置として磁気ディスク装置を用いることを特徴とするディスクアレイシステム。

【発明の詳細な説明】

[0001]

【産業上の利用分野】本発明は、PC、ワークステーションやサーバ等の計算機システム、ディスクアレイシステムに関わり、特に記憶装置に格納されたデータのデータアクセス制御方法および計算機システム並びにディス 40 クアレイシステムに関する。

[0002]

【従来の技術】近年のCPU性能の飛躍的な向上により、ワークステーションやサーバの演算性能は著しく向上した。しかしCPU性能の向上に比較して、I/O性能、特に磁気ディスク装置に格納されたファイルのアクセス速度の向上は十分とは言い難い。これは、磁気ディスク装置のような2次記憶装置のアクセス速度ネック、及びI/Oバスインタフェースの速度ネックが主な要因である。

3

【0003】このネックを解消して高速なファイルアクセスを実現する技術の一つとして、ディスクアレイ装置(もしくはアレイディスク装置と呼ぶ)がある。これは、磁気ディスク装置(以下、簡単のためにディスクドライブあるいは単にディスクと呼ぶ)を複数台内蔵する装置で、各ディスクを並列に動作させることにより、高速なファイルアクセスを実現しようとするものである。さらに、I/Oバスとの接続に高速なインタフェースを用いることにより、I/Oバスインタフェースの速度ネックの解消も図ろうとしている。

【0004】図46にアレイディスク装置の構成を、また図47にファイル読み出しの場合のタイムチャートを示す。図46及び図47は、各スタックが4台のディスクで構成されている例であるが、ディスク台数には増減があっても構わない。これらの図を用いてアレイディスク装置の動作を説明する。

【0005】アレイディスク装置300はホストCPU 装置400から読み出し命令を受けると、装置内部のコ ントローラ (図には示していない) が、まずスタック 0 のディスクhd0~3にほぼ同時にデータブロック読み 出しの起動をかける。スタック0の各ディスクはシー ク、回転待ちのあとにディスク媒体から当該データブロ ックを読み出す。ディスクから読み出されたデータブロ ック0~3は、それぞれ別々のFIFO (310~31 3) に格納される。この読み出し動作はスタック0のデ ィスクhd0~3でそれぞれ独立かつ並列に実行される ために、全体の読み出し処理の高速化が実現される。次 に、これらのデータブロック0~3は時分割で装置内部 の高速バス、すなわち i - B u s 3 2 0を介してそれぞ 30 れバッファ330に順次シーケンシャルに転送される。 このバッファ330で各ディスクから独立に読み出した データブロック0~3を正しい順序に整列する。そし て、高速なSCSIバス160を介してデータブロック 0~3をホストCPU装置400へ転送する。その後、 次の読み出し命令が発行されていれば、データブロック を読み出すべきスタックのディスクに対して、アレイデ ィスク装置内部のコントローラは直ちに読み出しの起動 をかける。また、信頼性を確保するために上記データブ ロックにパリティを用いる方法が知られている。

1 【0006】アレイディスク装置では、こうした一連の 動作を繰り返すことによって、高速なファイルアクセス を実現している。

【0007】なお、アレイディスク装置に関連する公知例としては、特開昭64-41044号「データ転送方式」、特開昭64-21525号「磁気ディスク制御装置」等がある。

[0008]

【発明が解決しようとする課題】上述のように、従来のアレイディスク装置では、パリティを用いて信頼性を確50 保している。このため上記の4台のアレイディスク例で

8

は、例えば、ディスクが1台故障した場合、他の3台に格納されている全てのデータをアクセスし、壊れたディスクに格納していたデータの復元を行うため、時間が掛かるという問題がある。

【0009】そこで本発明の目的は、ディスクやデータ が壊れた場合、高速に修復するデータアクセス制御方法 - や計算機システム、ディスクアレイシステムを提供する 。ことにある。

[0010]

【課題を解決するための手段】本発明は上記課題を解決することを目的とし、データを複数に分割した第1の分割データ群を複数の記憶装置のそれぞれに分配して格納し、上記データを複数に分割した第2の分割データ群を複数の記憶装置のそれぞれに分配して格納し、上記第1の分割データが壊れた場合は、上記壊れた第1の分割データに対応する上記第2の分割データを用いて上記第1の分割データを修復することにより上記課題を解決するものである。

【0011】図48に本発明の原理図を、また図49に本発明におけるファイル読み出しのタイムチャートを示 20 す。図48及び図49はディスク台数が4台の場合を示す例であるが、ディスク台数には増減があっても構わない。これらの図を用いて本発明の原理について説明する。

【0012】本発明においては、計算機システムにSCSIバスのようなディスコネクト・リコネクト機能を有するI/〇バス160を設けてホストCPU装置400と接続し、さらに、このI/〇バス160に内部キャッシュメモリ20 $-0\sim20-3$ を有する複数台の磁気ディスク装置170 $-0\sim170-3$ を接続し以下のアクセス制御を行う。

【0013】ファイルの書き込みを行う場合には、ホストCPU装置400は該当ファイルをサブファイルに分割して、これらを各磁気ディスク装置170-0~170-3の内部キャッシュメモリ20-0~20-3に次々に書き込んでゆく。ホストCPU装置400がサブファイルを構成するデータブロックを各磁気ディスク装置の内部キャッシュメモリに書き込み終わると、各磁気ディスク装置は書き込み終了をホストCPU装置400~知らせる。その後、各磁気ディスク装置内部で内部キャッシュメモリに書き込まれたデータが、それぞれシークと回転待ちの後にディスク媒体に書き込まれる。当然この間、ホストCPU装置400は他の磁気ディスク装置の内部キャッシュメモリへ他のサブファイルの書き込みを行うことができる。

【0014】ファイルの読み出しを行う場合には、ホストCPU装置400は、そのファイルを格納するサブファイルを読み出す命令を該当する各磁気ディスク装置170-0~170-3に対して次々に発行してゆく。発行後、I/Oバス160を介したホストCPU装置40

のと各磁気ディスク装置170-0~170-3との接続をディスコネクトする。一方、各磁気ディスク装置は読み出し命令を受け付けると、それぞれシークと回転待ちの後にディスク媒体からデータを内部キャッシュメモリへ読み出して、ホストCPU装置400に対してリコネクト要求を発行する。最も早くリコネクト要求を受け付けられた磁気ディスク装置から、ホストCPU装置400はデータの主記憶装置への読み込みを開始する。この間、他の磁気ディスク装置もホストCPUが発行した読み出し命令に基づき、ディスク媒体から内部キャッシュメモリへデータを読み出す動作を行い、読み出し完了と共にリコネクト要求をホストCPU装置400〜発行する。このようにして読み出したサブファイルはホストCPU装置400側で合成され、元ファイルが再生される。

【0015】上述したファイルアクセス動作において、磁気ディスク装置170-0~170-3の内部キャッシュメモリ20-0~20-3~のI/Oバス160を介してのアクセスは高速なI/Oバスの速度で行えるため、シークや回転待ち、およびディスク媒体と内部キャッシュメモリ間のデータ転送時間に比較し、極めて短時間に行えることになる。その結果、読み出し動作も書き込み動作も、ほぼ各磁気ディスク装置がそれぞれ独立に並行して行うことになるため、システム全体としては高速なファイルアクセスが実現されることになる。

【0016】以上に述べたように、ファイルの読み出しと書き込みのどちらの場合でも、磁気ディスク装置の内部キャッシュメモリの存在と、これに対するI/Oバスからのアクセスが高速なことを利用して、磁気ディスク装置の並列動作とI/Oバスの効率的な利用が実現できる。これにより、高速なファイルアクセスを可能とする計算機システムを提供することができる。

【0017】上記の各機能を実現するために、本発明の 提供する高速ファイルアクセス制御方法は、ディスコネ クトおよびリコネクト機能を有する少なくとも1本以上 の入出力バスを有し、それぞれバスインタフェース装置 を介して主記憶装置に接続された該入出力バスに各々異 なった装置として識別できる、内部キャッシュメモリを 備えた複数の外部記憶装置が接続された計算機システム において、(1)入出力バスに接続された複数の外部記 億装置の中から任意の複数の外部記憶装置を選択し、外 部記憶装置グループを定義した外部記憶装置の構成情報 を記憶したディスク管理情報を参照して、指定された外 部記憶装置グループからこれを構成する外部記憶装置名 称を求めるディスク構成情報参照ステップと、(2)ア クセスの対象となる元ファイルのファイル記述子とこれ を分割構成するサブファイルのファイル記述子とを対応 付けて記憶したファイル記述子管理情報を参照して、指 定された元ファイルのファイル記述子からこれを構成す 50 るサブファイルのファイル記述子を求めるサブファイル

記述子参照ステップと、(3)元ファイルを構成するサ ブファイルの、外部記憶装置グループ内の各外部記憶装 置上での格納位置情報を記憶したファイル管理情報を参 照して、指定されたサブファイル記述子から該サブファ イルが格納されるべき、あるいはすでに格納されている 該当外部記憶装置上の位置情報を求めるファイル位置情 ・報参照ステップと、(4)上記ファイル位置情報参照ス テップにより求められた各サブファイルを格納する外部 - 記憶装置名称および該当外部記憶装置上の格納位置情報 をもとに、ファイル書き込みの際には、書き込み対象と なる磁気ディスク装置と当該バスインタフェース装置を コネクトして主記憶装置から該当するサブファイルを当 該磁気ディスク装置の内部キャッシュメモリに転送し、 転送し終えた段階で該内部キャッシュメモリからディス ク媒体上への書き込み終了を待たずに、当該磁気ディス ク装置をバスインタフェース装置からディスコネクト し、次の格納対象となる磁気ディスク装置をコネクト し、書き込み対象サブファイルを該磁気ディスク装置の 内部キャッシュメモリへ転送し、転送終了次第ディスコ ネクトするという動作を次々に繰り返し、ファイル読み 出しの際には、読み出し対象のサブファイルを格納して いる磁気ディスク装置と当該バスインタフェース装置を コネクトして、該磁気ディスク装置に対して読み出し要 求を発行し、該磁気ディスク装置内のディスク媒体上の サブファイルが同装置内のキャッシュメモリへ転送され るのを待たずに、該磁気ディスク装置をディスコネクト し、直ちに次の磁気ディスク装置とコネクトして次のサ プファイルの読み出し要求を発行するという動作を繰り 返す一方、内部キャッシュメモリ上へサブファイルの読 み込みが終了したことを伝えてきた磁気ディスク装置か らリコネクトを行い、該当キャッシュメモリ上のサブフ ァイルを主記憶上へ読み出すという動作を行うファイル アクセス制御ステップから構成される。

【0018】なお、上記の複数台の磁気ディスク装置から構成される仮想的なディスク装置をバーチャルアレイディスク、または単にバーチャルアレイと呼ぶことにする。

[0019]

【作用】本発明において、上記の課題を解決するための 手段で述べた各処理ステップがどのように作用するのか を説明する。

【0020】まず、処理ステップ(1)では、ファイルシステムの指定されたディレクトリにバーチャルアレイディスクを割り当て、利用可能な状態とする。この際に、ディスク管理情報を参照してバーチャルアレイディスクを構成する磁気ディスク装置を認識し、構成要素である磁気ディスク装置をバーチャルアレイディスクとして利用可能な状態にする。

【0021】ディスク管理情報は、バーチャルアレイディスクがどの磁気ディスク装置から構成されるのかを定 50

義する。一般に、各磁気ディスク装置は複数のパーティションに分割して使用するので、個々の磁気ディスク装置とそのパーティションを指定することで利用する領域を確定できる。ディスク管理情報はバーチャルアレイディスクが使用する磁気ディスク装置とそのパーティションを管理する。

【0022】次に、処理ステップ(2)では、元ファイルのファイル記述子とこれを分割したサブファイルのファイル記述子との対応関係を登録したファイル記述子管理情報を参照して、サブファイルが格納された磁気ディスク装置にアクセスするためのサブファイルのファイル記述子を得る。

【0023】ファイル記述子管理情報は、元ファイルのファイル記述子と、バーチャルアレイディスクに格納したサブファイルのファイル記述子とのあいだの対応を管理する。これにより、サブファイルの格納された複数の磁気ディスク装置をアクセスすることが可能となる。ファイル読み出し、あるいは書き込みの場合には、アプリケーションプログラムから与えられた元ファイルのファイル記述子を、ファイル記述子管理情報を参照してサブファイルのファイル記述子に変換する。また、ファイルを新規に作成して書き込みを行う場合には、新たに元ファイルとサブファイルのファイル記述子を割り当てて、ファイル記述子管理情報にこれらの対応関係を登録する。これ以降、ファイルの分割された実体であるサブファイルのアクセスは、元ファイルのファイル記述子によって行うことができるようになる。

【0024】次に、処理ステップ(3)では、処理ステップ(2)で得たサブファイルのファイル記述子から、サブファイルのファイル管理情報を得る。これを用いてサブファイルを格納した磁気ディスク装置へアクセスする。

【0025】ファイル管理情報には、サブファイルが格納されている磁気ディスク装置、ストライピングブロック数、サブファイルを構成するデータブロックが格納されている位置を示す位置情報が登録されている。各サブファイルのファイル管理情報を参照して、どの磁気ディスク装置のどこに格納されたデータブロックを順にアクセスするのかを決定する。これにしたがってサブファイルを順にアクセスすることにより、元ファイルをアクセスすることとなる。

【0026】最後に、処理ステップ(4)では、バーチャルアレイディスクに格納されたファイルをアクセスする。実際の処理では元ファイルを格納する磁気ディスクへのアクセスとなる。

【0027】ファイルアクセスは読み出しと書き込みの場合とがあるが、いずれにせよ処理ステップ(3)で得られたサブファイルのファイル管理情報を用いる。ファイル管理情報は、サブファイルの磁気ディスク上での格納位置を管理する。したがって、各サブファイルのファ

イル管理情報からアクセスするデータブロックの格納位置を得て、次々に各サブファイルを格納する磁気ディスク装置にアクセス要求を発行する。この際に、各サブファイルをアクセスする順番はファイル記述子管理情報から得る。また、サブファイルを格納する各磁気ディスク装置に対して連続してアクセスするブロック数は、ストライピングブロックとしてファイル管理情報に登録されている。

・【0028】ファイル読み出しの場合には、読み出し対 象のサブファイルが格納されている磁気ディスク装置と I/Oバスインタフェース装置とをコネクトし、読み出 し要求を発行する。要求が発行されると、磁気ディスク 装置はヘッドの位置決めを行い、内部キャッシュメモリ ヘディスク媒体からデータを転送する。このために待ち 時間が生じる。したがって、磁気ディスク装置とI/O バスインタフェース装置とを一旦ディスコネクトする。 この間に他の磁気ディスク装置とI/Oバスインタフェ ース装置とをコネクトし、読み出し要求を発行すること ができる。この場合にも、やはりヘッドの位置決めと内 部キャッシュメモリへのデータ転送を行うための待ち時 20 間が生じるので、さらにまた別の磁気ディスク装置に読 み出し要求を発行することができる。ヘッドの位置決め が完了して読み出しが可能となった磁気ディスク装置か らデータブロックを読み出し、その直後に次に読み出す データブロックの読み出し要求を発行し、磁気ディスク 装置とI/Oバスインタフェース装置とをディスコネク トするよう制御する。この様にして次々に読み出し要求 を各磁気ディスク装置に発行して、サブファイルを主記 憶上に読み込むことにより、元ファイルの読み込み処理 を行う。

【0029】ファイル書き込みの場合には、格納対象と なる磁気ディスク装置とI/Oバスインタフェース装置 とをコネクトし、書き込み要求を発行する。要求発行後 にデータブロックを磁気ディスク装置へ転送する。転送 されたデータブロックは磁気ディスク装置の内部キャッ シュメモリに書き込まれ、ヘッドの位置決めが完了する とディスク媒体へ書き込まれる。この際に、内部キャッ シュメモリへのデータブロック書き込みの終了をもっ て、磁気ディスク装置とI/Oバスインタフェース装置 とをディスコネクトし、磁気ディスク装置への書き込み を終了とする。したがって、内部キャッシュメモリから ディスク媒体への書き込み終了を待たずに、次の磁気デ ィスク装置とI/Oバスインタフェース装置とをコネク トして、書き込み要求発行とデータブロックの転送を行 うことができる。この様にして次々に書き込み要求を各 磁気ディスク装置へ発行して、元ファイルをサブファイ ルに分割しつつ主記憶上から書き込むことにより、元フ ァイルの書き込み処理を行う。

【0030】以上の各処理ステップによるファイルアク セスにおいて、ファイル読み出しの場合には、磁気ディ

スク装置のディスク媒体から内部キャッシュメモリへの データ転送の間に、次の磁気ディスク装置に読み出し要 求を発行できるために、複数の磁気ディスク装置に渡っ て読み出し処理の多重制御を行うことが可能となる。こ れにより、各磁気ディスク装置でのシークと回転待ち、 および内部キャッシュメモリへのデータ転送が並列に実 行される。このため各磁気ディスク装置にサブファイル の読み出し要求を発行し終わると、リコネクト要求をう けて各磁気ディスク装置からデータブロックを読み出す 際には、内部キャッシュメモリには主記憶へ読み出し可 10 能なサブファイルのデータブロックが常に存在すること となる。これらを順に読み出しながら次の読み出し要求 を発行し、その後に次の読み出し可能な磁気ディスク装 置の処理に移って行くように制御することで、I/Oバ スの利用効率の高い、高速なファイル読み出しが実現可 能となる。

【0031】ファイル書き込みの場合には、磁気ディスク装置の内部キャッシュメモリからディスク媒体へのデータ転送の間に、その終了を待たずに次の磁気ディスク装置に対して書き込み要求を発行できるために、複数の磁気ディスク装置に渡って書き込み処理の多重制御を行うことが可能となる。これにより、各磁気ディスク装置でのシークと回転待ち、および内部キャッシュメモリからディスク媒体へのデータ転送が並列に実行される。このため、各磁気ディスク装置にサブファイルの書き込み要求を順に発行することにより、高速なファイル書き込みが実現可能となる。

【0032】しかも以上のファイルアクセスにおいて、アプリケーションプログラムでは元ファイルのファイル 30 記述子のみを意識すれば良く、サブファイルに分割して 格納されていることを意識する必要がない。したがって、単体の磁気ディスク装置に格納されたファイルと同様のアプリケーションインタフェースでアクセスすることが可能である。

【0033】上述のように、本発明では以上の各処理ステップにより複数の磁気ディスク装置を順にアクセスして並列動作させることにより、高速なファイルアクセスを実現する。

[0034]

【実施例】図1に本発明の第1の実施例を示す。本実施例の構成は、共通なデータバス101に接続されたCPU100、メモリ110、CRTディスプレイ120、キーボード130、ネットワークインタフェース140、及びI/Oバスインタフェース150からなる計算機システムである。

【0035】 I /Oバスインタフェース150には、 I /Oバス160が接続され、この I /Oバス160に7 台の磁気ディスク装置 $170-0\sim170-6$ が接続されている。磁気ディスク装置の台数は7台以外の構成も取りうる。各磁気ディスク装置 $170-0\sim170-6$

とI/Oバス160との間、及びI/Oバスインタフェ ース150内にはディスコネクト・リコネクト装置18 0-0~180-7があり、磁気ディスク装置170-0~170-6が I/Oバス160を介して I/Oバス インタフェース150とデータの送受信を行わないとき には、両者の電気的な接続を解放(ディスコネクト)す ・ることができる。再び電気的な接続が必要になったとき には、再接続(リコネクト)することができる。これら の制御はCPUと磁気ディスク装置とが協調して行う。 気ディスク装置170-0~170-6の内部にディス クコントローラ(図には示していない)とともに内蔵す る構成も可能である。

【0036】ネットワークインタフェース140はネッ トワーク191に接続され、本ネットワーク191に接 続された遠隔地のワークステーション190等からのリ モートアクセスを可能とする。

【0037】次に本実施例の動作について、まずファイ ルをディスクに書き込む場合を例に説明する。

【0038】本実施例の計算機システムでは、ファイル 10は固定長のデータブロックの集合としてOS (オペ レーティングシステム)で管理されている。すなわち、 図1に示すように、A10-0、B10-1、C10-2, D10-3, E10-4, F10-5, G10-6、H10-7、I10-8、J10-9、...とい う一連の複数のブロックから構成される。

【0039】従来技術によるファイル書き込みの場合に は、1個の磁気ディスク装置を選択し、その特定の磁気 ディスク装置に対して書き込み処理を行う。すなわち、 データブロックA10-0、B10-1、C10-2、. . . を同一磁気ディスク装置、例えば170-0 に対して書き込むことになる。その際、データブロック はまず磁気ディスク装置170-0の内部キャッシュメ モリ (図示せず) に書き込まれ、シークと回転待ちの後 にディスグ媒体(図示せず)上に書き込まれる。CPU 100は内部キャッシュメモリ (以後、簡単のために内 部キャッシュとも表記する) にデータを書き込むと、デ ィスク媒体への書き込みが終了するまで次の書き込み処 理には進まずに待ち状態(wait状態)に入る。した がって、この場合ブロックA10-0のディスク媒体へ の書き込みが完全に終了して、初めて次のプロック B1 0-1の書き込みを実行することが可能となる。これ は、ブロックB10-1を磁気ディスク装置170-0 へ書き込もうとしても、内部キャッシュ上のデータのデ ィスク媒体への書き込みが終了していないため、書き込 みが行えないからである。

【0040】一方これに対して、本実施例では複数の磁 気ディスク装置にファイルを分割して格納する。例え ば、固定長のデータブロックから構成され、メモリ11 0に格納されているファイル10を、1データブロック

を I / Oの単位として、図1の i d = 0 から3までの4 台の磁気ディスク装置170-0~170-3へ分割し て格納する。この際、まずデータブロックA10-0を i d = 0の磁気ディスク装置170-0へ書き込む。デ ータブロックA10-0は磁気ディスク装置170-0 の内部キャッシュにまず書き込まれ、次にシークと回転 待ちの後にディスク媒体上の所定位置に書き込まれる。 これにより書き込み処理が終了することになる。本実施 例では、内部キャッシュからディスク媒体への書き込み なお、上述したディスコネクト・リコネクト装置は、磁 10 終了を待つことなく、磁気ディスク装置170-0の内 部キャッシュへの書き込みが終了した時点で、次のデー タブロックであるブロックB10-1をid=1の磁気 ディスク装置170-1へ書き込むという処理を行う。 ここでも同様に、データブロックB10-1の内部キャ ッシュからディスク媒体への書き込み終了を待つことな く、次のデータブロックC10-2をid=2の磁気デ ィスク装置170-2へ書き込む処理を行う。以下同様 にして、データブロックC10-2の内部キャッシュか らディスク媒体への書き込み終了を待つことなく、デー タブロックD10-3をid=3の磁気ディスク装置1 70-3へ書き込む。データブロックD10-3の磁気 ディスク装置170-3の内部キャッシュへの書き込み が終了した後、 i d = 0 の磁気ディスク装置 1 7 0 - 0 へ戻り、内部キャッシュからディスク媒体へのデータブ ロックA10-0の書き込みが終了していることを確認 した上で、ブロックD10-3の書き込み終了を待つこ となくブロックE10-4を磁気ディスク装置170-0の内部キャッシュに書き込む。 i d=0の磁気ディス ク装置への書き込みが終了するのに十分な時間が取れな 30 い場合には、全体の磁気ディスク装置の台数を増やせば 良い。これにより、さらにファイル書き込みの性能を向 上させることができる。以下、データブロックF10-5, G10-6, H10-7, I10-8, J10-9、...についても同様の方法で、異なる磁気ディス ク装置170-1、170-2、170-3、170-0、...と、順にデータブロックを書き込んでゆく。 すべて書き込み終わると、元ファイルの内容を4分割し た4個のサブファイルが別々の磁気ディスク装置170 -0~170-3に格納されたことになる。

> 【0041】この様に、磁気ディスク装置の内部キャッ シュからディスク媒体へのデータブロックの書き込みの 終了を待たずに、次の磁気ディスク装置へのデータブロ ックの書き込み要求を発行する機能を非同期書き込みと 呼ぶ。

> 【0042】非同期書き込みによりサブファイルを磁気 ディスク装置に書き込んでいる時、各磁気ディスク装置 170-0~170-6とI/Oバスインタフェース1 50がI/Oバス160を介して電気的に接続されるの は、データブロックが磁気ディスク装置の内部キャッシ 50 ュヘ転送される間のみである。すなわち、ホストCPU

100から書き込み要求が発行されると、磁気ディスク 装置がI/Oバスインタフェース150と電気的に接続 され、データブロックの転送が可能となる。磁気ディス ク装置の内部キャッシュへのデータブロックの書き込み が終了すると、磁気ディスク装置とI/Oバスインタフ ェース150との電気的接続が開放される。その後磁気 ディスク装置内部で、内部キャッシュからディスク媒体 へのデータ書き込みが独立して行われる。したがって、 .ホストCPU100はこの間に異なる次の磁気ディスク 装置へアクセスすることができるため、磁気ディスク装 置の内部キャッシュへのデータブロックの書き込みを終 了したら、直ちに次の磁気ディスク装置に対する書き込 み要求を発行し、この磁気ディスク装置と I / Oバスイ ンタフェース150との電気的接続を確立した後にデー タブロックの転送を行うことができる。

【0043】ファイル読み出しの場合についても、本実 施例は図1のファイル書き込みの場合と同様に動作す る。すなわち、id=0の磁気ディスク装置170-0 から順にデータブロックを読み出していく。ホストCP U100は読み出し命令を磁気ディスク装置170-0 から170-1、170-2、... へと順に発行して 行く。命令を受け取った磁気ディスク装置はシークと回 転待ちを行なうことなく、直ちにディスク媒体からデー タブロックを読み込める場合を除き、一旦I/Oバスイ ンタフェース150との電気的接続を開放する。その 後、シークと回転待ちを行なってから、ディスク媒体の 所定位置からデータを読み込むシーケンスを開始する。 したがって、ホストCPU100は磁気ディスク装置1 70-0へ読み出し命令を発行した後、直ちに次の読み み出し命令を発行することが可能となる。

【0044】この様に、磁気ディスク装置からのデータ ブロックの読み出し終了を待たずに、次の磁気ディスク 装置に対してデータブロックの読み出し要求を発行する 機能を非同期読み出しと呼ぶ。

【0045】以下、同様にしてホストCPU100は次 々に170-2、170-3の磁気ディスク装置へ読み 出し命令を発行する。一方、各磁気ディスク装置170 -0~170-3の内部では、ディスク媒体から内部キ ャッシュヘデータが読み出されるとホストCPU100 に対してリコネクト要求を発行し、I/Oバスインタフ ェース150との電気的接続を確立した後にホストCP U100へのデータ転送を行う。これら、ディスク媒体 から内部キャッシュへのデータ読み出しは、それぞれの 磁気ディスク装置とも相互に独立に、かつ並列に動作す ることが可能である。すなわち、ファイルの読み出しの 場合についても、本実施例では分割したファイルを異な る複数の磁気ディスク装置から読み出すため、磁気ディ スク装置の内部キャッシュの効果的な働きにより各磁気 ディスク装置の並列動作が可能となる。これにより高速 50 の磁気ディスク装置170-0とid=1の磁気ディス

なファイル読み出しが可能となる。

【0046】以上の説明にあるI/Oバス160を介し てのディスコネクト・リコネクト機能は、例えばSCS Iインタフェース(Small Computer System Interface、 ANSI×3.131-1986規格) にサポートされており、本実施 例のI/OバスもSCSIインタフェースの装置を用い ることにより実現が可能である。

【0047】図2にファイル読み出し(readと記す場合 もある)の場合のタイムチャートを示す。(1)に従来技 術である1台の磁気ディスク装置を用いる場合を、(2) に本発明のバーチャルアレイディスクを4台の磁気ディ スク装置で構成して用いる本実施例の場合をそれぞれ示 す。図中のI/Oバスの軸はI/Oバス160のタイム チャートであり、 i d の軸は磁気ディスク装置のタイム チャートである。 I/Oバス軸上では、ホストCPU1 00と磁気ディスク装置170-0~170-3との間 で行われる読み出しリクエスト、データ転送のタイミン グを示す。各id軸上では、ディスク媒体から内部キャ ッシュへのデータ転送のタイミング、および内部キャッ 20 シュから I / Oバス 1 6 0 へのデータ転送のタイミング を示す。

【0048】まず、(1)の1台の磁気ディスク装置の場 合について動作を説明する。ホストCPU100から磁 気ディスク装置へ読み出し命令が発行され起動が掛かる と、磁気ディスク装置内部のコントローラでコマンド解 析が行われ、磁気ディスク装置のソフトウェアオーバへ ッドT1が生じる。その後、ディスク媒体からデータブ ロックを読み出すためのヘッドの位置決めが行われ、 (シーク時間+回転待ち時間) T 2 が生じる。この間、磁 出し対象となる磁気ディスク装置170-1に対して読 30 気ディスク装置はディスコネクトされた状態となる。へ ッドの位置決め終了後、磁気ディスク装置はリコネクト され、ディスク媒体からデータブロックを内部キャッシ ュへ読み出しながら、同時に内部キャッシュから I / O バス160〜出力する。このためデータ転送時間T3が 生じる。

> 【0049】一方、(2)の4台の磁気ディスク装置で構 成されるバーチャルアレイディスクの場合には、ホスト CPU100からid=0~3の4台の磁気ディスク装 置へそれぞれ順に読み出し命令が発行され起動が掛か

> 【0050】まずid=0の磁気ディスク装置170-0に読み出し命令が発行されると、コマンド解析後磁気 ディスク装置170-0はシークと回転待ちに入り、同 時にディスコネクトされる。これによりホストCPU1 00は次のid=1の磁気ディスク装置170-1に読 み出し命令を発行することができるようになる。 id= 1の磁気ディスク装置170-1もid=0の磁気ディ スク装置と同様に、コマンド解析後シークと回転待ちに 入り同時にディスコネクトされる。このとき、id=0

ク装置170-1はそれぞれ独立に並列動作していることになる。さらにホストCPU100は次のid=2の磁気ディスク装置170-2、id=3の磁気ディスク装置170-3にも同様の手順で読み出し命令を次々に発行する。これらの磁気ディスク装置も同様に、コマンド解析後シークと回転待ちに入り同時にディスコネクトされる。この時点で4台の磁気ディスク装置がそれぞれ・全く独立に並列動作することになる。

17

・【0051】 i d=3の磁気ディスク装置170-3が ディスコネクトされた後、 i d = 0 の磁気ディスク装置 170-0がヘッドの位置決めを完了してデータの読み 出しが可能となっていれば、あるいはデータがディスク 媒体から読み出されて内部キャッシュに格納されていれ ば、ホストCPU100に対してリコネクト要求を発行 する。ホストCPU100はリコネクト要求を受け付け ると、id=0の磁気ディスク装置170-0からデー タの読み込みを行う。この際、あらかじめデータが内部 キャッシュに格納されていれば、ディスク媒体からの読 み出し時間T3より短い時間T4(T3>T4)で高速に データを読み出すことができる。読み込みが終了する 20 と、id=0の磁気ディスク装置170-0に対して次 の読み出し命令を発行する。 i d = 0の磁気ディスク装 置170-0は先程と同様に、コマンド解析後シークと 回転待ちに入り同時にディスコネクトされる。この時、 i d=1の磁気ディスク装置170-1が読み出し可能 となっていれば、id=0の磁気ディスク装置170-0の場合と同様にホストCPU100は磁気ディスク装 置170-1からのリコネクト要求を受け付けて、デー タを読み込む。読み込みが終了すると、 i d = 1 の磁気 ディスク装置170-1に対して次の読み出し命令を発 30 行する。そして、本磁気ディスク装置170-1もコマ ンド解析後シークと回転待ちに入り同時にディスコネク トされる。さらにホストCPU100は次のid=2の 磁気ディスク装置170-2、及び i d = 3の磁気ディ スク装置170-3に対しても同様の手順でリコネクト 要求を受け付け、データ読み込み、及び次の読み出し命 令の発行を行う。以後、このシーケンスが図2に示され るように繰り返される。なお、本図では(シーク時間+ 回転待ち時間)T2を定数と仮定しているが、実際は各 読み出し命令発行の都度異なることが多いそのような場 合には、最も早くリコネクト要求を出してきた磁気ディ スク装置から順にデータを読み込むということも可能で ある。その際に、データを読み出す磁気ディスク装置を 選択する順序が前後することになるが、それ以外の上記 の手順は変わらない。図2では、id=0の磁気ディス ク装置170-0のみがディスク媒体から直接データ転 送を行い、他の i dの磁気ディスク装置170-1~1 70-3は内部キャッシュからデータ転送を行うかたち になっている。このためデータ転送時間に差が生じてい る。これはすなわち、ホストCPU100がデータを読 50

み込むまでに内部キャッシュへデータが読み込まれている場合にはデータ転送時間は短くなり、読み込まれていない場合にはディスク媒体からの読み出しとなりデータ 転送時間は短くはならないためである。

【0052】図2からも明らかなように、本発明では常に4台の磁気ディスク装置が並列に動作しており、単位時間あたりのホストCPU100のデータ読み込み量が実効的に磁気ディスク装置の台数分倍増するという効果が得られる。すなわち、本発明によればファイルの読み出し速度がほぼ磁気ディスク装置の台数分高速化されることになる。

【0053】図2で示したファイル読み出し(read)の、より一般化した制御フロー(1)~(8)を図3に示す。使用する磁気ディスク装置n台はあらかじめ指定されており、これらにファイルが分割して格納されているものとする。これらのファイル読み出しに必要な情報は、例えばアプリケーションプログラムから与えるものとする。また、ファイルアクセスのシーケンス、および非同期読み出しの制御はホストCPU100が行う。

20 【0054】以下、制御フローの各ステップについて説明する。

【0055】(1) i d=0~(n-1) の磁気ディスク 装置に対して読み出し要求(readリクエスト)を順次発行する。

【0056】(2)いずれかの磁気ディスク装置が読み出 し可能状態となるまで待つ。

【0057】(3)読み出し可能な磁気ディスク装置があれば次のステップ(4)へ進み、なければステップ(2)へ戻る。

30 【0058】(4)読み出し可能な磁気ディスク装置の i d 番号をチェックし、記憶する。

【0059】(5)ステップ(4)でチェックした id=kの磁気ディスク装置から、データを読み出す。

【0060】(6)読み出し終了であればフローを終了し、読み出し終了でなければ次のステップ(7)へ進む。【0061】(7)id=kの磁気ディスク装置からさらにデータを読み出すのであれば次のステップ(8)へ進み、もうデータを読み出さないのであればステップ(2)へ戻る。

(0 【0062】(8) i d = kの磁気ディスク装置に対して 読み出し要求(readリクエスト)を発行し、ステップ(2) へ戻る。

【0063】以上の制御フローにより、バーチャルアレイディスクからの高速なファイル読み出しを行うことができる。

【0064】図4にファイル書き込み(writeと記す場合もある)の場合のタイムチャートを示す。(1)に従来技術である1台の磁気ディスク装置を用いる場合を、(2)に本発明のバーチャルアレイディスクを4台の磁気ディスク装置で構成して用いる場合をそれぞれ示す。図中の

I/Oバスの軸、idの軸の意味はそれぞれ図2と同様である。

【0065】まず、(1)の1台の磁気ディスク装置の場 合について動作を説明する。ホストCPU100から磁 気ディスク装置へ書き込み命令が発行され起動が掛かる と、磁気ディスク装置内部のコントローラでコマンド解 - 析が行われ、磁気ディスク装置のソフトウェアオーバへ ッドT1が生じる。この時に、ホストCPU100は書 . き込むデータを磁気ディスク装置へ転送し、データは直 ちに内部キャッシュへ格納される。この時データ転送時 間T4が生じる。これをもって、ホストCPU100か らのデータ書き込み処理は終了したものとみなされる。 その後、磁気ディスク装置ではディスク媒体へデータブ ロックを書き込むためのヘッドの位置決めが行われ、 (シーク時間+回転待ち時間) T 2 が生じる。この間、磁 気ディスク装置はビジー状態となる。ヘッドの位置決め 後、磁気ディスク装置はデータブロックを内部キャッシ ュからディスク媒体へ書き込む。このためデータ転送時 間T3が生じる。

【0066】一方、(2)の4台の磁気ディスク装置で構成されるバーチャルアレイディスクの場合には、ホスト CPU100からid=0~3の4台の磁気ディスク装置170-0~170-3~、それぞれ順に書き込み命令が発行されて起動が掛かる。

【0067】まずid=0の磁気ディスク装置170-0に書き込み命令が発行され、引き続き書き込むデータが転送されて磁気ディスク装置の内部キャッシュへ格納される。これにより、ホストCPU100からのデータ書き込み処理は終了したものとみなされる。磁気ディスク装置はコマンド解析後、シークと回転待ちに入る。

【0068】ヘッドの位置決めが完了すると、内部キャ ッシュのデータがディスク媒体に書き込まれる。一方、 ホストCPU100は次のid=1の磁気ディスク装置 170-1に書き込み命令を発行し、引き続き書き込む データを転送することができるようになる。 id=1の 磁気ディスク装置170-1も i d=0の磁気ディスク 装置170-0と同様に、コマンド解析後シークと回転 待ちに入り内部キャッシュからディスク媒体へのデータ 書き込みを行う。このとき、 i d = 0 の磁気ディスク装 置170-0とid=1の磁気ディスク装置170-1 は各々独立に並列動作していることになる。さらにホス トCPU100は次のid=2の磁気ディスク装置17 0-2、id=3の磁気ディスク装置170-3にも同 様の手順で書き込み命令の発行とこれに引き続くデータ 転送を次々に実行する。これらの磁気ディスク装置も同 様に、コマンド解析後シークと回転待ちに入り、ヘッド の位置決めが完了すると、内部キャッシュのデータをデ ィスク媒体に書き込む。この時点で4台の磁気ディスク 装置170-0~170-3が、それぞれ独立に並列動 作することになる。

【0069】id=3の磁気ディスク装置170-3に 書き込み命令の発行と書き込みデータの転送を行った 後、id=0の磁気ディスク装置170-0のデータ書 き込みが完了していれば、次のデータの書き込みが可能 である。そこで、次の書き込み命令の発行とデータ転送 とを実行する。id=0の磁気ディスク装置170-0 は先程と同様にコマンド解析後シークと回転待ちに入 る。この時、id=1の磁気ディスク装置170-1の データ書き込みが完了していれば、次のデータの書き込 10 みが可能である。そこで i d = 0の磁気ディスク装置 1 70-0の場合と同様に、ホストCPU100は磁気デ ィスク装置へ次の書き込み命令の発行とデータ転送とを 実行する。そして、コマンド解析後シークと回転待ちに 入る。さらにホストCPU100は次のid=2の磁気 ディスク装置170-2、id=3の磁気ディスク装置 170-3にも前に発行したデータ書き込みの完了を確 認すると、同様の手順で次の書き込み命令の発行を行 う。以後、このシーケンスが図4に示されるように繰り 返される。なお、本図では(シーク時間+回転待ち時間) T2を定数と仮定しているが、実際は各書き込み命令の 発行の都度異なることが多い。そのような場合には、最 も早くビジー状態が解除されて書き込み可能な状態とな った磁気ディスク装置から順にデータを書き込むという ことも可能である。

【0070】データを書き込む磁気ディスク装置を選択 する順序が前後することになるが、それ以外の上記の手 順は変わらない。

【0071】図4からも明らかなように、本発明では常に4台の磁気ディスク装置が並列に動作しており、単位 30 時間あたりのホストCPU100のデータ書き込み量が 実効的にディスク台数分倍増するという効果が得られ る。すなわち、本発明によればファイル書き込み速度が 磁気ディスク装置の台数分高速化されることになる。

【0072】図4で示したファイル書き込み(write) の、より一般化した制御フロー(1)~(7)を図5に示す。使用する磁気ディスク装置 n 台はあらかじめ指定されており、これらにファイルを分割して格納するものとする。これらのファイル書き込みに必要な情報は、例えばアプリケーションプログラムから与えるものとする。また、ファイルの複数磁気ディスク装置への分割、ファイルアクセスのシーケンス、および非同期書き込みの制

【0073】以下、制御フローの各ステップについて説明する。

【 0 0 7 4】(1) i d = 0 ~ (n - 1) の磁気ディスク 装置に対して以下の処理を順次実行する。 1. 書き 込み要求(writeリクエスト)を発行する。

【0075】2. 書き込みデータを転送する。

御はホストCPU100が行う。

【0076】(2)いずれかの磁気ディスク装置が書き込 50 み可能状態となるまで待つ。

【0077】(3)書き込み可能な磁気ディスク装置があ れば次のステップ(4)へ進み、なければステップ(2)へ 戻る。

【0078】(4)書き込み可能な磁気ディスク装置の i d番号をチェックし、記憶する。

【0079】(5) i d = k の磁気ディスク装置にさらに *データを書き込むのであれば、次のステップ(6)へ進

・ み、もうデータを書き込まないのであればステップ(2) ・ヘ戻る。

【0080】(6) i d = kの磁気ディスク装置に対して 10 る。 以下の処理を順次実行する。

【0081】1. 書き込み要求(writeリクエスト)を発 行する。

【0082】2. 書き込みデータを転送する。

【0083】(7)書き込み終了であればフローを終了 し、書き込み終了でなければステップ(2)へ戻る。

【0084】以上の制御フローにより、バーチャルアレ イディスクへの高速なファイル書き込みを行うことがで きる。

【0085】以上に説明したように本実施例ではファイ ルを分割して異なる複数の磁気ディスク装置への書き込 み、および読み出しを行うことにより、各磁気ディスク 装置の並列動作が可能となり高速なファイルアクセスが 実現される。また、アレイディスク装置のように専用の ハードウェアを必要とせず、例えばSCSIバスを用い ることにより、7台までの磁気ディスク装置を1枚のア ダプタボードで接続することが可能となる。このため、 非常に低コストで高速なファイルアクセス機能を実現す ることができる。

【0086】また、SCSIインタフェースの仕様を拡 張すれば、7台以上の磁気ディスク装置を接続すること も可能であることは明らかである。さらに、本実施例で は固定長のデータブロックを各磁気ディスク装置に分散 格納する場合を例にして説明したが、可変長のデータブ ロックでも同様の処理が可能である。

【0087】図6に本発明の第2の実施例を示す。第2 の実施例は、ファイルが複数のサブファイルに分割され て別々の磁気ディスク装置に格納されていることをアプ リケーションプログラムから意識しなくとも、ファイル にアクセスできるようにした実施例である。

【0088】以下の各テーブルとプログラムとを用い て、バーチャルアレイディスクとして使用する磁気ディ スク装置の指定、ファイルの複数サブファイルへの分割 と磁気ディスク装置への対応付け、複数のサブファイル を一まとまりのファイルに見せるアクセス制御、および 非同期読み出しと非同期書き込みの制御を行う。

【0089】ディスク管理情報を格納するためのディス ク管理テーブル210、ファイル管理情報を格納するた めのファイル管理テーブル220、ファイル記述子対応 情報を格納するためのファイル記述子対応テーブル23

0をメモリに保持する。アクセス制御プログラム200 は、バーチャルアレイディスクを対象とするファイルの 書き込みと読み出しの際に、上記各テーブルを参照して アクセス制御を行う。

【0090】上記各テーブル、およびプログラムは計算 機システムのメモリに格納される。

【0091】なお、上記の各テーブルはアプリケーショ ンプログラムから与えることも、OSの内部の管理テー ブルとして管理することも、いずれの方法も可能であ

【0092】各テーブルの具体的な構成を以下に説明す

【0093】図7はディスク管理テーブル210の説明 図である。ディスク管理テーブルには、どの磁気ディス ク装置のどのパーティション(分割領域)を用いてバー チャルアレイディスクを構成するのかということに関す る情報が格納される。

【0094】各磁気ディスク装置には、SCSIインタ フェースで磁気ディスク装置の識別に用いる i d番号 と、アプリケーションソフトウェアが磁気ディスク装置 の識別に用いる磁気ディスク装置名称が割り当てられ る。また、通常磁気ディスク装置は複数のパーティショ ンに分割して使用するので、各パーティションにはパー ティション番号が付けられる。したがって、 i d番号ま たは磁気ディスク装置名称とパーティション番号との組 合せで、システム内の磁気ディスク装置を利用する際の 単位領域の指定を行うことができる。これを"論理ディ スク装置"と呼ぶことにする。本図に示した例では、デ イスク装置名称 h d 6 のディスク装置の各パーティショ 30 ンが論理ディスク装置として定義されており、例えば第 5パーティションは名称が h d 6 5の論理ディスク装置 となる。この論理ディスク装置を複数組み合わせて、 "論理バーチャルアレイディスク装置"として使用す

【0095】ディスク管理テーブル210は磁気ディス ク装置の i d番号または名称とパーティション番号との マトリクスであり、これらのどの組合せの論理ディスク 装置が論理バーチャルアレイディスク装置として定義さ

れているのかを示している。

【0096】名称がhd0からhd3の4台の磁気ディ 40 スク装置をバーチャルアレイディスク装置 v a Oとして 定義することとし、その各第0パーティションを図1ま たは図6に示すような論理バーチャルアレイディスク装 置va00として用いる場合には、va000からva 003までを識別子として図7に示すように書き込む。 これにより磁気ディスク装置hd0からhd3の第0パ ーティションを論理バーチャルアレイディスク装置va 00として定義したことになる。

【0097】ここで識別子vaXYZ(ただし、X、 50 Y、Zは一桁の数字)は、この論理ディスク装置がバー

チャルアレイディスク装置vaXの構成要素であり、か つバーチャルアレイディスク装置vaXの第Yパーティ ションからなる論理バーチャルアレイディスク装置 va XYの構成要素であり、さらにその論理バーチャルアレ イディスク装置 va XYの第2番目の構成要素となる論 理ディスク装置であるということを示している。

【0098】なお、ディスク管理テーブル210の設定 ・は、本計算機システムのシステム構成を定義する時点で ・システム管理者が行う。これは、ディスク管理テーブル 210の設定内容が、各論理ディスク装置の使用状態、 すなわち通常のファイル格納に使われているのか、サブ ファイルの格納に使われているのかということと整合が 取れていなければならないからである。

【0099】以上のディスク管理テーブル210の設定 により、後述するmount処理を論理バーチャルアレ イディスク装置va00に対して行うと、hd0~hd 3の4台の磁気ディスク装置の第0パーティションを論 理バーチャルアレイディスク装置va00として利用す ることが可能となる。

【0100】図8はファイル管理テーブル220の説明 20 図である。ファイル管理テーブル220は各サブファイ ルごとに割り付けられ、それぞれファイル属性領域と、 ディスクブロックインデックス領域に分けられる。各サ ブファイルのファイル記述子がファイル管理テーブル2 20-0~220-nの先頭を指し示すことにより、フ ァイル管理テーブル220はファイル記述子と関連付け られている。

【0101】ファイル属性領域は、ファイルタイプ、フ ァイルサイズ、格納デバイス、およびストライピングブ ロックを格納するエントリから構成される。ファイルタ イプには、このテーブルが管理するファイルがバーチャ ルアレイディスク装置に格納されるサブファイルである のか、通常の磁気ディスク装置に格納されるファイルで あるのかを示す識別子が格納される。ファイルサイズに は、サブファイルの容量が格納される。格納デバイスに は、サブファイルが格納される磁気ディスク装置の実体 である、論理ディスク装置の名称が格納される。ストラ イピングブロックには、ファイルをこのサブファイルに 分割した際に単位としたデータブロックの個数が格納さ れる。すなわち各サブファイルは、このデータブロック の個数ごとにファイルを先頭から分割して作られる。

【0102】ディスクブロックインデックス領域には、 データプロックのインデックス情報としてディスク上の 論理ブロック番号を格納する。本図では、ファイルを構 成する各データブロックが論理ブロック番号100、2 00、300、... 900に格納されていることにな

【0103】ファイル管理テーブル220はバーチャル アレイディスクに格納するファイルが作られるときに、 アクセス制御プログラムによってサブファイルごとに作 50 ち、論理バーチャルアレイディスク装置を構成する論理

られる。以後、このファイルが消去されるまでファイル 管理テーブルは存続し、ファイルを構成する各サブファ イルをアクセスする際にアクセス制御プログラムがこれ を参照する。バーチャルアレイディスクに格納されたフ アイルが消去されるときに各サプファイルが消去される ことになり、この時同時にファイル管理テーブルも消去 される。

【0104】図9はファイル記述子対応テーブル230 の説明図である。バーチャルアレイディスクに格納され ている元ファイルのファイル記述子vfdと、分割後の サブファイルのファイル記述子 f d との対応を示してい

【0105】本図の例では、vfd=4である元ファイ ルは、4個のサブファイルからなり、それぞれのファイ ル記述子は、fd0=5、fd1=6、fd2=7、f d3 = 8 である。また、v f d = 20 の元ファイルにつ いても同様に、サブファイルのファイル記述子は f d O = 21, fd1 = 22, fd2 = 23, fd3 = 24 $^{\circ}$ あることを示している。

【0106】バーチャルアレイディスクに格納されてい るファイルをアクセスする際には、まずファイルをop enしなければならない。この時に、元ファイルのファ イル記述子vfdがアクセス制御プログラムにより割り 当てられる。次にその実体であるサブファイルの名称が 元ファイルの名称から生成され、このサブファイル名称 を用いてサブファイルがopenされる。この時に各サ ブファイルにファイル記述子 f d 0~ f d 3 が割り当て られる。以後、アプリケーションプログラムからこのフ ァイルをアクセスする場合にはファイル記述子vfdを 用いる。アクセス制御プログラムはファイル記述子対応 テーブル230を用い、これをサブファイルのファイル 記述子fd0~fd3に変換して各サブファイルのアク セスを行う。ファイル記述子対応テーブルのエントリ は、ファイルをcloseする際に解放されて内容は無 効となる。

【0107】以上説明したディスク管理テーブル21 0、ファイル管理テーブル220、およびファイル記述 子対応テーブル230を用いて、バーチャルアレイディ スクを制御する際の概略の手順について説明する。

【0108】図10に制御の全体のフローを示す。各ス テップは、ユーザからのコマンド、あるいはプログラム からの関数コールによって起動される処理を示してい る。各処理はメモリに格納されたアクセス制御プログラ ムによって実行される。以下、本図の制御フローに従っ てその内容を説明する。

【0109】mount処理では、バーチャルアレイデ ィスクをOSが管理するディレクトリの指定された場所 に割り付け、その指定ディレクトリ名称下のデバイスと してソフトウェアから利用可能な状態とする。すなわ

ディスク装置を、ディスク管理テーブル210を参照し てディレクトリの指定された場所に割り付ける処理を行 なう。

【0110】open処理では、元ファイル及びサプフ ァイルにファイル記述子を割り当て、ファイル記述子対 - 応テーブル230に対応関係が取れるように登録する。

·【0111】read/write処理では、read 処理指定時にはバーチャルアレイディスクからのファイ ・ル読み出しを行い、write処理指定時にはバーチャ ルアレイディスクへのファイル書き込みを行う。いずれ の場合も、元ファイルのファイル記述子からファイル記 述子対応テーブル230によりサブファイルのファイル 記述子を得る。さらにファイル記述子によりファイル管 理テーブル220を得て、サブファイルの格納されてい る論理ディスク装置にアクセスする。

【0112】close処理では、元ファイルとサブフ ァイルのクローズ処理、すなわち元ファイルに割り当て たファイル記述子と、サブファイルに割り当てたファイ ル記述子の解放を行う。

【0113】umount処理では、論理バーチャルア レイディスク装置として指定ディレクトリに割り付けら れた各論理ディスク装置を指定ディレクトリから除去す

【0114】このため、その指定ディレクトリ名称下の デバイスとしてソフトウェアから意識できなくなる。

【0115】以下、各処理の詳細な制御フローを図1 1、図12、図13、図14、図15、図16、および 図17を用いて説明する。

【0116】mount処理の制御フロー(1)~

(3)を図11を用いて説明する。なお、/devで始 まる装置名称は、mount処理やumount処理で 用いられるフルパス名称である。

【0117】(1)マウントする論理バーチャルアレイ ディスク装置に対応する磁気ディスク装置の名称、パー ティション番号、すなわち論理ディスク装置の名称をデ ィスク管理テーブル210から得る。

【0118】(2)論理バーチャルアレイディスク装置 をマウントするディレクトリに、マウント用のディレク トリを作る。例えば図12に示すように論理バーチャル アレイディスク装置の名称が/dev/va00である 場合には、名称が". v a 0 0"というディレクトリを まずマウントディレクトリ/dataの下に作り、さら にその下に、すなわち/data/.va00の下に名 称が ". va000"、 ". va001"、 ". va00 2"、および". v a 0 0 3"というディレクトリを作 る。

【0119】(3) ディスク管理テーブル210を参照 して、各ディレクトリ".va000"、".va00 1"、". va002"、および". va003"に対応 hd03をマウントする。

【0120】図12には、mount処理の結果により 構成されるトリー構造が示されている。

【0121】このようにmount処理ではトリー構造 を持つディレクトリ下にバーチャルアレイディスクがマ ウントされ、バーチャルアレイディスク内のファイルが トリー構造のディレクトリによって管理される。この例 では、"/data"ディレクトリに論理バーチャルア レイディスク装置"/dev/va00"がマウントさ 10 れている。各磁気ディスク装置には同一構造のディレク トリが構成され、その下に各サブファイルが格納される ことになる。ここでは、各サブファイル名称とディレク トリ名称に添字を付して区別してある。

【0122】open処理の制御フロー(1)~(5) を図13を用いて説明する。

【0123】(1)オープン対象として指定された元フ ァイルの名称から、添字を付してサブファイルの名称を 生成する。

【0124】例えば、図12のディレクトリ構造におい て、元ファイルとして/data/fileを指定する と、これからサブファイルのファイル名称

/data/.va00/.va000/file0、 /data/.va00/.va001/file1, /data/.va00/.va002/file2, /data/.va00/.va003/file3, を生成する。

【0125】(2)サブファイルのファイル名称を用い て個々のサブファイルをオープンし、ファイル記述子 f d0~fd3を割当てる。これにより、各サブファイル 30 のファイル記述子 f d 0 ~ f d 3 がファイル管理テープ ル220に対応付けられ、アプリケーションプログラム からのファイル記述子を用いたアクセスが可能となる。

【0126】(3)元ファイルにファイル記述子vfd を割り当てる。

【0127】(4)元ファイルのファイル記述子vfd とサブファイルのファイル記述子fdO~fd3とを対 にして、ファイル記述子対応テーブル230に登録す る。(5) 元ファイルのファイル記述子vfdを、本o pen処理の結果として、すなわちopenコールの戻 り値としてアプリケーションプログラムへ返す。

【0128】次にread/write処理でのrea d 処理実行の制御フロー(1)~(5)について図14 を用いて説明する。

【0129】(1)アプリケーションプログラムからは 元ファイルのファイル記述子vfdを引き数にしてアク セス要求が発行される。引数であるファイル記述子vf dをキーとしてファイル記述子対応テーブル230を検 索し、vfdに対応するサブファイルのファイル記述子 fdO~fd3を得る。図9に示すように例えば元ファ する論理ディスク装置/dev/hd00~/dev/ 50 イルのファイル記述子vfdが4の場合、サブファイル

のファイル記述子 f d $0 \sim$ f d 3 として 5 、6 、7 、8 が得られる。

【0130】 (2) 次に、サブファイルのファイル記述 子 $fd0 \sim fd3$ から、これらのサブファイルのファイ ル管理テーブル220を得る。

【0131】(3) サブファイルをアクセスする順番 は、ディスク管理テーブル210の記述子の添字の順に - 行う。この順にサブファイルのファイル管理テーブル2 ・20を参照し、読み込むデータブロックの論理ブロック 番号を得る。図7に示す例では、論理ディスク装置/dev/hd01、/dev/hd02、/dev/hd01、/dev/hd02、/dev/hd03の順にアクセスすることになる。ファイル管理テーブル220に書かれたストライピングブロックが指定するデータブロック数だけアクセスしたら、次のサブファイルへアクセスする。すなわち、次のサブファイルのファイル管理テーブルを参照して、ストライピングブロックが指定するデータブロック数だけアクセスする。この手順にしたがって、読み込むデータブロックの論理ブロック番号を順に得る。

【0132】(4) 磁気ディスク装置から読み込むデータブロックの論理ブロック番号と、サブファイルのファイル管理テーブル220の格納デバイスエントリに書かれた論理ディスク装置とにしたがって、データブロックを読み込む。実際にアクセスする磁気ディスク装置は、ディスク管理テーブル210を参照して、該当論理ディスク装置をその一部として含む磁気ディスク装置として得ることができる。

【0133】(5)最後に、読み込むべきデータブロックをすべて読み込んだかどうか判定する。まだ読み込むべきデータブロックがあれば、(3)に戻って繰り返す。

【0134】次にread/write処理でのwrite処理実行の制御フロー(1)~(7)について図15を用いて説明する。サブファイルのデータブロックをアクセスする手順の概略は、read処理実行時と同様である。

【0135】(1) アプリケーションプログラムからは元ファイルのファイル記述子 v f dを引き数にしてアクセス要求が発行される。引数であるファイル記述子 v f dをキーとしてファイル記述子対応テーブル 230を検索し、 v f dに対応するサブファイルのファイル記述子 f d 0~f d 3を得る。図9に示すように例えば元ファイルのファイル記述子 v f dが4の場合、サブファイルのファイル記述子 f d 0~f d 3として5、6、7、8が得られる。

【0136】 (2) 次に、サブファイルのファイル記述 子 $fd0\sim fd3$ から、これらのサブファイルのファイル管理テーブル220を得る。

【0137】(3)既存ファイルの内容を更新する場合には、データブロックの内容を上書きすれば良い。しか 50

し、ファイルサイズを超えて追加書き込みを行う場合には、書き込むために新しい領域を割り当てる必要が生じる。したがって、新しいディスクブロックの割当てが必要であるかどうかを判定し、必要であれば(4)へ、不要であれば(5)へ進む。

【0138】(4) ディスクブロックを割り当てる際に、どのサブファイルが格納されている論理ディスク装置から割り当てるのかを決める。ファイルの最終部分となっているサブファイルの総データブロック数が、ファイル管理テーブルのストライピングブロックエントリに書かれたデータブロック数の整数倍である場合、次のサブファイルを格納する論理ディスク装置からデータブロックの割り当てを行う。そうでなければ、ファイル最終部分のサブファイルが格納されている論理ディスク装置から割り当てを行う。データブロックを割り当てた後に、そのデータブロックの論理ブロック番号を得る。次は(6) へ進む。

【0139】(5) read処理の場合で述べたように元ファイルはサブファイルに分割されており、これにより元ファイルに合成するためのアクセスする順番は決定される。したがって、その手順に従い書き込み箇所に該当するサブファイルのファイル管理テーブル220から、ファイルが書き込まれるデータブロックの論理ブロック番号を得る。

【0140】(6)磁気ディスク装置へ書き込むデータブロックの論理ブロック番号と、サブファイルのファイル管理テーブル220の格納デバイスエントリに書かれた論理ディスク装置とにしたがって、データブロックを書き込む。実際にアクセスする磁気ディスク装置は、ディスク管理テーブル210を参照して、該当論理ディスク装置をその一部として含む磁気ディスク装置として得ることができる。

【0141】(7)最後に、書き込むべきデータブロックをすべて書き込んだかどうか判定する。まだ書き込むべきデータブロックがあれば、(3)に戻って繰り返す。

【0142】 close処理の制御フロー(1)~(3)を図16を用いて説明する。

【0143】(1) アプリケーションプログラムからは 元ファイルのファイル記述子vfdを引き数にして処理 要求が発行される。ファイル記述子vfdをキーとして ファイル記述子対応テーブル230を検索し、vfdに 対応するサブファイルのファイル記述子fd0~fd3 を得る

【0144】 (2) サブファイルに対応するファイル記述子 f d 0~ f d 3を解放する。

【0 1 4 5】 (3)元ファイルに対応するファイル記述 子vf d を解放する。

【0146】最後に、umount処理の制御フロー(1)~(3)を図17を用いて説明する。

【0147】(1) ディスク管理テーブル210を参照 して、アンマウントする論理バーチャルアレイディスク 装置を構成する論理ディスク装置に対応する、磁気ディ スク装置の名称とパーティション番号を得る。

【0148】(2)上記、論理ディスク装置をアンマウ - ントする。すなわち図12の例では、ディレクトリ". ・va000"、".va001"、".va002"、お . よび ". va003" から/dev/hd00~/de v/hd30を除去する。

【0149】(3) バーチャルアレイディスクのマウン ト用に作ったディレクトリを消去する。 すなわち図12 の例では、". va00"、".va000"、".va 001"、 ". va002"、および ". va003" を 消去する。

【0150】以上説明したように、ディスク管理テープ ル210によりバーチャルアレイディスクを定義し、フ ァイル記述子対応テーブル230により元ファイルとサ ブファイルとの対応付けを行い、ファイル管理テーブル 220を参照してサブファイルへアクセスすることによ り、ユーザは複数のサブファイルにアクセスすることを 全く意識せず、あたかも単一のファイルにアクセスする のと全く同じ形でバーチャルアレイディスクを利用する ことができるという効果が得られる。

【0151】次に図18~21を用いてファイルのスト ライピング処理について説明する。

【0152】図1に示した実施例では、データブロック 1個を単位としたファイルのサブファイルへの分割、す なわちストライピングを行っている。この場合、データ ブロックAから順にB、C、Dを、磁気ディスク装置の id番号0番から順に1番、2番、3番へと格納する。 そして、次のデータブロックEから順にF、G、Hを、 同様に磁気ディスク装置の i d番号O番から順に1番、 2番、3番へと格納する。この場合のファイルの書き込 みの様子を図18に、ファイルの読み出しの様子を図1 9に示す。

【0153】図18はファイルを先頭から順に書き込む 場合を示している。 I / Oバスインタフェース150を 介して、ホストCPU100からデータブロックが順に 送られる。ディスコネクト・リコネクト機能により各磁 気ディスク装置が I / Oバスインタフェース 1 5 0 と順 40 に接続されて、データブロック 0、1、2、3、

4. . . が i d番号0番、1番、2番、3番、0 番...の磁気ディスク装置へと格納される。なお、格 納する磁気ディスク装置の順序は必ずしも i d 番号の順 である必要はなく、0番以外の磁気ディスク装置から開 始することも可能である。また、id番号の順序を昇 順、または降順以外とすることも可能である。

【0154】図19はファイルを先頭から順に読み出す 場合を示している。I/Oバスインタフェース150を

られる。図18に示したようにデータブロックは格納さ れており、ディスコネクト・リコネクト機能により各磁 気ディスク装置が I / Oバスインタフェース 1 5 0 と順 に接続されて、データブロック 0、1、2、3、

30

4...がid番号0番、1番、2番、3番、0 番...の磁気ディスク装置から読み出される。なお、 格納する磁気ディスク装置の順序は必ずしも i d 番号の 順である必要はなく、0番以外の磁気ディスク装置から 開始することも可能である。また、id番号の順序を昇 10 順、または降順以外とすることも可能である。

【0155】一方、複数個のデータブロックをストライ ピングの単位とすることも可能である。一例として、デ ータブロック4個を単位としてストライピングを行った 場合のファイルの書き込みの様子を図20に、ファイル の読み出しの様子を図21に示す。

【0156】図20はデータブロック4個を単位として ファイルを先頭から順に書き込む場合を示している。I /Oバスインタフェース150を介して、ホストCPU 100からデータブロックが順に送られる。ディスコネ クト・リコネクト機能により各磁気ディスク装置がI/ Oバスインタフェース150と順に接続されて、データ プロック0、1、2、3がid番号0番、データブロッ ク4、5、6、7が i d番号1番、データブロック8、 9、10、11がid番号2番、データブロック12、 13、14、15がid番号3番、データブロック1 6、17、18、19がid番号0番...の磁気ディ スク装置へとそれぞれ格納される。なお、格納する磁気 ディスク装置の順序は必ずしも i d 番号の順である必要 はなく、0番以外の磁気ディスク装置から開始すること 30 も可能である。また、id番号の順序を昇順、または降 順以外とすることも可能である。

【0157】図21はデータブロック4個を単位として ファイルを先頭から順に読み出す場合を示している。 I /Oバスインタフェース150を介して、ホストCPU 100ヘデータブロックが順に送られる。図20に示し たようにデータブロックは格納されており、ディスコネ クト・リコネクト機能により各磁気ディスク装置が I/ Oバスインタフェース150と順に接続されて、データ ブロック 0、1、2、3が i d番号0番、データブロッ ク4、5、6、7がid番号1番、データブロック8、 9、10、11がid番号2番、データブロック12、 13、14、15がid番号3番、データブロック1 6、17、18、19がid番号0番...の磁気ディ スク装置からとそれぞれ読み出される。なお、格納する 磁気ディスク装置の順序は必ずしもid番号の順である 必要はなく、0番以外の磁気ディスク装置から開始する ことも可能である。また、id番号の順序を昇順、また は降順以外とすることも可能である。

【0158】なお、ストライピングの単位とするデータ 介して、ホストCPU100ヘデータブロックが順に送 *50* ブロック数は、4個以外の任意の個数を取りうることは 言うまでもない。

【0159】図22~33を用いて、論理バーチャルア レイディスク装置として使用する論理ディスク装置の組 合せについて説明する。

【0160】本実施例では、ディスク管理テーブル21 Oで磁気ディスク装置の i d 番号または名称と、パーテ ・ィション番号とを指定して使用する論理ディスク装置を 定義する。図7の説明で述べたように、複数の論理ディ スク装置に一連の識別子vaXYO、vaXY

1、...を付けることで、論理バーチャルアレイディ スク装置として利用する論理ディスク装置の組合せの定 義が可能である。識別子の添字の意味は、図7のディス ク管理テーブルの説明で述べたとおりである。本実施例 ではサブファイルの物理的な配置の自由度が非常に高 く、以下のような構成が可能である。なお、例えば図7 のディスク装置名称 h d 4、 h d 5 のディスク装置のよ うに、論理バーチャルアレイディスク装置として定義し ていない領域は、特に断わりがなくとも通常の論理ディ スク装置として利用可能である。

【0161】図22はid番号0、1、2、3の4台の 磁気ディスク装置のすべてのパーティションを論理バー ヂャルアレイディスク装置として用いる場合である。

【0162】これに対応するディスク管理テーブル21 0の設定例を図23に示す。4台の磁気ディスク装置を バーチャルアレイディスク装置 va0として定義し、全 体をひとつの論理バーチャルアレイディスク装置 va0 0として用いる場合に相当する。 i d 番号4、5、6の 3台の磁気ディスク装置は、通常の磁気ディスク装置と して用いる。

【0163】図24はid番号0、1、2、3の4台の 30 磁気ディスク装置の特定のパーティションを用いる場合 である。

【0164】これに対応するディスク管理テーブルの設 定例を図25に示す。図23と同様に定義したバーチャ ルアレイディスク装置vaOの第Oパーティションを論 理バーチャルアレイディスク装置vaOOとして用いる 場合である。id番号4、5、6の3台の磁気ディスク 装置は、通常の磁気ディスク装置として用いる。

【0165】図26はid番号0、1、2、3の4台の 磁気ディスク装置の各3つのパーティションを用いて、 論理バーチャルアレイディスク装置を3組定義した場合 である。

【0166】これに対応するディスク管理テーブル21 0の設定例を図27に示す。図23と同様に定義したバ ーチャルアレイディスク装置 v a 0 の第 0 、第 1 、第 2 パーティションを、それぞれ論理バーチャルアレイディ スク装置va00、va01、va02として用いる場 合である。 i d番号4、5、6の3台の磁気ディスク装 置は、通常の磁気ディスク装置として用いる。

磁気ディスク装置の特定のパーティション、およびid 番号4、5の2台の磁気ディスク装置の特定のパーティ ションを用い、論理バーチャルアレイディスク装置を2 組定義した場合である。

【0168】これに対応するディスク管理テーブル21 0の設定例を図29に示す。id番号0、1、2、3の 4 台の磁気ディスク装置をバーチャルアレイディスク装 置vaO、id番号4、5の2台の磁気ディスク装置を バーチャルアレイディスク装置 v a 1 としてそれぞれ定 10 義し、各々の第0パーティションをそれぞれ論理バーチ ヤルアレイディスク装置vaOO、valOとして用い る場合である。id番号6の磁気ディスク装置は、通常 の磁気ディスク装置として用いる。

【0169】図30はid番号0、1、2、3の4台の 磁気ディスク装置の各3つのパーティション、およびi d番号4、5の2台の磁気ディスク装置の各3つのパー ティションを用い、論理バーチャルアレイディスク装置 を6組定義した場合である。

【0170】これに対応するディスク管理テーブル21 20 0の設定例を図31に示す。図29と同様に定義したバ ーチャルアレイディスク装置vaO、valの第O、第 1、第2パーティションを、それぞれ論理バーチャルア レイディスク装置vaOO、vaO1、vaO2、およ びvalO、vall、val2として用いる場合であ る。 i d番号6の磁気ディスク装置は通常の磁気ディス ク装置として用いる。

【0171】図32はid番号0、2の2台の磁気ディ スク装置の各3つのパーティション、id番号4、6の 2台の磁気ディスク装置の各2つのパーティション、お よびid番号1、3の2台の磁気ディスク装置の各1つ のパーティションを用い、論理バーチャルアレイディス ク装置を3組定義した場合である。

【0172】これに対応するディスク管理テーブル21 0の設定例を図33に示す。id番号0、2、4、6の 4台の磁気ディスク装置をバーチャルアレイディスク装 置va0、id番号0、1、2、3の4台の磁気ディス ク装置をバーチャルアレイディスク装置valとしてそ れぞれ定義し、vaOの第O、第2パーティションをそ れぞれ論理バーチャルアレイディスク装置vaOO、v 40 a 0 2 として、valの第1パーティションを論理バー チャルアレイディスク装置vallとして用いる場合で ある。id番号0、2の2台の磁気ディスク装置はva Oとvalとに重複して定義されることになるが、利用 するパーティションが重ならないようにすれば問題は生 じない。なお、id番号5の磁気ディスク装置は、通常 の磁気ディスク装置として用いる。 以上の各構成例に おいて、磁気ディスク装置の台数及び i d 番号は、上記 以外の組合せでも実現可能である。

【0173】図34~39は本実施例においてミラーモ 【0167】図28はid番号0、1、2、3の4台の *50* ードを実現する例である。すなわち、論理バーチャルア

レイディスク装置としてプライマリ(正)とバックアップ(副)を一組にして定義し、同一ファイルを両方に格納するものである。これにより、プライマリに障害が発生した場合には、バックアップを替わりに使用することにより信頼性向上を図ることができる。

【0174】ファイル書き込みの場合には、プライマリ・とバックアップの両方に書き込む。

. 【0175】まずプライマリとして定義した論理バーチ・ヤルアレイディスク装置に対して、非同期書き込みによりデータブロックを書き込む。引き続き、バックアップとして定義した論理バーチャルアレイディスク装置に対しても、やはり非同期書き込みによりプライマリと同様のデータブロックを書き込む。バックアップへの書き込み命令を発行した後、次のデータブロックの書き込み処理に移り、プライマリおよびバックアップに対して上記と同様の手順によりデータブロックを書き込む。

【0176】なお、プライマリとバックアップへの書き込み方に関しては、各論理バーチャルアレイディスク装置を構成する対応するディスク装置ごとに、すなわちhd0とhd2、hd1とhd3というように書き込むことも、その逆にhd0とhd3、hd1とhd2というように書き込むことも可能である。これは、ディスク管理テーブルに設定された識別子vaXYZのZの値をキーとして対応を取ることにより行う。具体的な例は図35の説明で述べる。

【0177】これにより、ユーザにはバックアップへの 書き込み時間をほとんど感じさせずに、ミラーモードを 実現することができる。

【0178】ファイル読み出しの場合には、プライマリのみから読み出しを行う。すなわち、ミラーモード指定 30を行っていない論理バーチャルアレイディスク装置に格納されたファイルを読み出すのと同様の方法で、プライマリからファイルの読み出しを行う。しかし、プライマリに障害が発生すると、バックアップに格納されたファイルを替わりに使用する。

【0179】これにより、磁気ディスク装置の信頼性を向上することができる。また、通常の利用状態ではプライマリのみからファイルを読み出すので、バックアップが存在することによるペナルティが発生することなく、高速にファイルの読み出しが行える。

【0180】以下、図を用いて、ミラーモードでの論理
バーチャルアレイディスク装置として使用する論理ディ
スク装置の組合せについて説明する。ミラーモードでな
い論理バーチャルアレイディスク装置の定義の場合と同様に、ディスク管理テーブル210により使用する論理
ディスク装置に一連の識別子を付けることで定義を行
う。さらに、プライマリであるのかバックアップである
のかということと、その組合せを拡張子により示す。例
えば、vaXYZ_p0は識別子vaXYZの論理ディ
スク装置がシステム中でミラーモードのプライマリ論理 50

バーチャルアレイディスク装置の構成要素として定義されており、バックアップ論理バーチャルアレイディスク装置の構成要素として定義されるva XYZ_b0の論理ディスク装置と対をなすということを示す。なお、論理バーチャルアレイディスク装置として定義していない領域は、特に断わりがなくとも通常の論理ディスク装置として利用可能である。

【0181】図34はid番号0、1の2台の磁気ディスク装置の各1つのパーティションを用いてプライマリとし、id番号2、3の2台の磁気ディスク装置の各1つのパーティションを用いてバックアップとして、ミラーモードの論理バーチャルアレイディスク装置を1組定義した場合である。

【0182】これに対応するディスク管理テーブル210の設定例を図35に示す。id番号0、1の2台の磁気ディスク装置をバーチャルアレイディスク装置va0、id番号2、3の2台の磁気ディスク装置をバーチャルアレイディスク装置va1としてそれぞれ定義し、各々の第0パーティションをそれぞれ論理バーチャルアレイディスク装置va00_p0(プライマリ)、va10_b0(バックアップ)として用いる場合である。本図の例では、プライマリを構成する論理ディスク装置va000-p0、va001-p0に、バックアップを構成する論理ディスク装置va100-b0、va101-b0がそれぞれ対応する。id番号4、5、6の磁気ディスク装置は、通常の磁気ディスク装置として用いる。

【0183】図36はid番号0、1、2、3の4台の磁気ディスク装置の各2つのパーティションを用いて、第1パーティションをプライマリとし、第2パーティションをバックアップとして、ミラーモードの論理バーチャルアレイディスク装置を1組定義した場合である。

【0184】これに対応するディスク管理テーブル210の設定例を図37に示す。id番号0、1、2、3の4台の磁気ディスク装置をバーチャルアレイディスク装置va1として定義し、第1、第2パーティションをそれぞれ論理バーチャルアレイディスク装置va11_p1(プライマリ)、va12_b1(バックアップ)として用いる場合である。id番号4、5、6の磁気ディ40スク装置は、通常の磁気ディスク装置として用いる。

【0185】図38はid番号0、1、2、3の4台の磁気ディスク装置のひとつのパーティションを用いてプライマリとし、id番号3、4、5、6の4台の磁気ディスク装置のひとつのパーティションを用いてバックアップとして、ミラーモードの論理バーチャルアレイディスク装置を1組定義した場合である。

【0186】これに対応するディスク管理テーブル21 0の設定例を図39に示す。id番号0、1、2、3の 4台の磁気ディスク装置をバーチャルアレイディスク装 置va2、id番号3、4、5、6の4台の磁気ディス ク装置をバーチャルアレイディスク装置 va3としてそ れぞれ定義し、各々の第3、第4パーティションをそれ ぞれ論理バーチャルアレイディスク装置 v a 2 3 _ p 2 (プライマリ)、va34_b2(バックアップ)とし て用いる場合である。

【0187】図40は本発明の第3の実施例である。図 1に示した第1の実施例におけるid番号0、1、2、 3の磁気ディスク装置170-0~170-3をアレイ . ディスク装置300-0~300-3に置き換えたもの て装置単体でのファイル転送性能が高いので、本実施例 は第1の実施例に比べてより一層ファイルアクセス高速 化の効果が得られる。

【0188】なお、動作や制御方式は図1の第1の実施 例と全く同様である。

【0189】これに対応する、アレイディスク装置30 0-0~3~0~0-3を含むバーチャルアレイディスクの ディスク管理テーブルの設定例を図41に示す。id番 号0、1、2、3の4台がアレイディスク装置となって いる。ここでは4台のアレイディスク装置adO、ad 1、ad2、およびad3でバーチャルアレイディスク 装置vaOを構成している。

【0190】また本実施例においても、論理バーチャル アレイディスク装置 v a 0 1 __ p 0 と v a 0 2 __ b 0、 va21_p1とva22 b1のようにミラーモード に対応することも可能である。

【0191】これまでの実施例では7台の磁気ディスク 装置が接続された場合を例に取り説明したが、磁気ディ スク装置の台数を2台、3台、4台...と順次増やし て行くことも可能である。ここで、例えば4台の磁気デ ィスク装置を5台に増やした場合、4台のディスクに格 納されていたファイルを5台の磁気ディスク装置に再配 置することが必要となる。

【0192】本発明によれば、磁気ディスク装置の増設 後に新たなパーティションへファイルをコピーすること により、ファイルのストライピング数を自動的に増加さ せて行くことも可能となる。すなわち、バーチャルアレ イディスク装置に格納されたファイルを読み書きする場 合、ユーザはファイルの物理的な分割を意識することな く処理を行うことができるため、コピー元からコピー先 40 ヘファイルをコピーするだけで、ユーザがこれを特に意 識することなく、ストライピング数の変換を行うことが 可能である。この場合について以下に説明する。

【0193】図42にディスク管理テーブル210の設 定例を、図43にディスク増設時のファイルコピーの制 御フローをそれぞれ示す。図42において、磁気ディス ク装置の i d番号0、1、2、3の第0パーティション により構成されている論理バーチャルアレイディスク装 置vaOOはコピー元であり、磁気ディスク装置のid 番号 O 、 1 、 2 、 3 、 4 の第 1 パーティションにより構 50 ータ転送速度を達成することができる。その場合、 I /

成されている論理バーチャルアレイディスク装置val 1はコピー先である。

【0194】図43に示す制御フローに従って、va0 Oからvallへファイルを固定長のデータに分割して コピーする。

【0195】(1)コピー先の論理バーチャルアレイデ ィスク装置vallをディスク管理テーブル210に定 義する。

【0196】(2)コピー元の論理バーチャルアレイデ である。アレイディスク装置は磁気ディスク装置に比べ 10 ィスク装置va00から、図14のファイル読み出しの 制御フローによりファイルを分割した固定長のデータを 読み込み、これをコピー先の論理バーチャルアレイディ スク装置 v a 1 1 へ、図15のファイル書き込みの制御 フローにより書き込む。

> 【0197】(3)コピー終了か判定し、まだ残りがあ れば(2)に戻って繰り返す。コピー終了であれば (4) へ進む。

> 【0198】(4)ディスク管理テーブル210上のコ ピー元の論理バーチャルアレイディスク装置va00を 無効化する。

> 【0199】以上により、磁気ディスク装置の増設に伴 うストライピング数の変更が容易に可能となる。この際 に、読み出しおよび書き込みの単位とする固定長のデー タとしては、任意のブロック数を定義することができ る。

【0200】図44は複数のI/Oバスを有する本発明 の一実施例である。図1の第1の実施例の構成では1/ Oバスは1本であったが、図44では4本のI/Oバス を有する構成となっている。したがって、I/Oバスイ 30 ンタフェース150、151、152、153とI/O バス160、161、162、163、さらに各1/0 バスごとの7台の磁気ディスク装置170-0~170 -6, $171-0\sim171-6$, $172-0\sim172-$ 6、173-0~173-6からなる4組のディスクサ ブシステムを設けている。アクセス制御プログラムが複 数のI/〇バスへのスケジューリングを行う点を除け ば、各ディスクサブシステムの制御方法は前述の各実施 例のものをそのまま適用することが可能である。例え ば、各 I / Oバスごとに第1の実施例のような多重アク セス制御を行い、さらに I / Oバス間での 1 階層上での 多重アクセス制御を行うということが可能である。ま た、各I/Oバスごとの多重アクセス制御を並列に行う ことも可能である。

【0201】各1/0バス160、161、162、1 63と共通データバス101間でのデータ転送におい て、共通データバスの速度が I / Oバスの速度の 4 倍よ りも大きく、なおかつ上述のような制御方式を用いるこ とによりデータ転送の相手が特定のI/Oバスに集中す ることがないような場合には、本図の実施例は最大のデ 〇バスが1本の第1の実施例に比較して本図の実施例では4倍のデータ転送速度となる。したがって、本実施例によりバーチャルアレイディスクの高速性をさらに高めることが可能となる。なお、本図ではI/〇バスが4本の場合について示したが、もちろん4本以外の構成を取ることも可能である。

【図3】第
- ムを拡張する場合には、各 I / Oバス内での磁気ディス
- ク装置の増設と、 I / Oバス単位での増設が可能であ
る。このため、1 スタックごとに磁気ディスク装置の増 10 ムチャート
設を行わなければならないアレイディスク装置に比べ、
よりフレキシブルにシステムの拡張に対応することがで
きるという長所を有する。
【図6】第

【0203】この様に本実施例によれば、バーチャルアレイディスク装置を用いたファイルアクセスの一層の高速化と、柔軟なシステムの拡張性を同時に実現することができるという効果がある。

【0204】図40の第3の実施例に示したように、図44の実施例の磁気ディスク装置をアレイディスク装置 に置き換えた構成を取ることも可能である。この実施例20を図45に示す。図45では、第0番のI/Oバスの磁気ディスク装置がアレイディスク装置300-0~300-6となっている。これにより、より一層のファイルアクセス高速化を図ることが可能となる。この際、原理的にはアレイディスク装置は任意の磁気ディスク装置と入れ替えることが可能であり、本図に示した以外の構成も容易に実現することが可能である。

【0205】なお、上記図44、および図45に示した 複数のI/Oバスを有する実施例においても、1本のI /Oバスを有する実施例の説明中で述べた本発明の種々 の機能を実現することが可能なことは明らかである。

【0206】本発明によれば、ディスコネクト・リコネクト機能を備えた I / Oバスを有する計算機システムにおいて、該 I / Oバスに接続された複数のディスク装置にファイルを分割格納してソフトウェアで多重・並列アクセス制御することで、高価なハードウェアを用いることなく、アレイディスク装置に匹敵するほどの高速なファイルアクセスを実現することができるという効果がある。しかも、ユーザはあたかも1台のディスク装置を使っているかのごとく、複数のディスクに分割されたファイルをアクセスすることができるようになる。これにより、従来よりも非常に低コストで高速ファイルアクセス可能な計算機システムを実現することができるという効果が得られる。

【0207】また、特殊なハードウェアを用いないので、ディスク装置の増設の際には1台づつ増設していくことができ、柔軟なシステム拡張が可能であるという効果もある。

[0208]

【発明の効果】本発明によれば、高速なデータアクセス 50

可能な計算機システムを実現することができるという効果が得られる。

【図面の簡単な説明】

【図1】第1の実施例を示す図

【図2】第1の実施例におけるファイル読み出しのタイムチャート

【図3】第1の実施例におけるファイル読み出しのフローチャート

【図4】第1の実施例におけるファイル書き込みのタイムチャート

【図5】第1の実施例におけるファイル書き込みのフローチャート

【図6】第2の実施例を示す図

【図7】ディスク管理テーブルを示す図

【図8】ファイル管理テーブルを示す図

【図9】ファイル記述子対応テーブルを示す図

【図10】ファイルアクセスの全体フローチャート

【図11】mount処理の制御フローチャート

【図12】ディレクトリ構造を示す図

【図13】open処理の制御フローチャート

【図14】read処理の制御フローチャート

【図15】write処理の制御フローチャート

【図16】close処理の制御フローチャート

【図17】umount処理の制御フローチャート

【図18】データブロック1個を単位とするストライピ ングを示す図

【図19】データブロック1個を単位とするストライピ ングを示す図

【図20】データブロック4個を単位とするストライピ 30 ングを示す図

【図21】データブロック4個を単位とするストライピ ングを示す図

【図22】バーチャルアレイディスクの使用領域を示す 図

【図23】ディスク管理テーブルの設定例を示す図

【図24】バーチャルアレイディスクの使用領域を示す 図

【図25】ディスク管理テーブルの設定例を示す図

【図26】バーチャルアレイディスクの使用領域を示す

【図27】ディスク管理テーブルの設定例を示す図

【図28】バーチャルアレイディスクの使用領域を示す 図

【図29】ディスク管理テーブルの設定例を示す図

【図30】バーチャルアレイディスクの使用領域を示す 図

【図31】ディスク管理テーブルの設定例を示す図

【図32】バーチャルアレイディスクの使用領域を示す 81

【図33】ディスク管理テーブルの設定例を示す図

【図34】ミラーモードの使用領域を示す図

【図35】ミラーモードでのディスク管理テーブルの設 定例を示す図

【図36】ミラーモードの使用領域を示す図

【図37】ミラーモードでのディスク管理テーブルの設 定例を示す図

【図38】ミラーモードの使用領域を示す図

【図39】ミラーモードでのディスク管理テーブルの設 * 定例を示す図

【図40】アレイディスクを含む構成の第3の実施例を 示す図

【図41】アレイディスクを含むディスク管理テーブル の設定例を示す図

【図42】ディスク増設時のファイルコピーのディスク 管理テーブルの設定例を示す図

【図43】ディスク増設時のファイルコピーの制御フロ ーチャート

【図44】複数のI/Oバスを有する実施例を示す図

【図45】複数のI/Oバスを有しアレイディスクを含む実施例を示す図

【図46】アレイディスクの構成を示す図

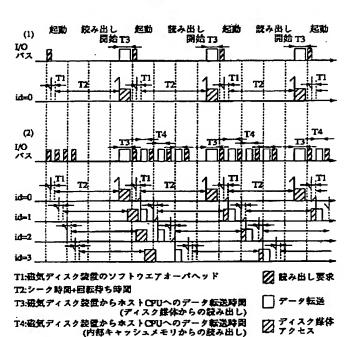
【図47】アレイディスクのタイムチャート

【図48】本発明の原理図

【図49】本発明におけるファイル読み出しのタイムチ

【図2】

图 2



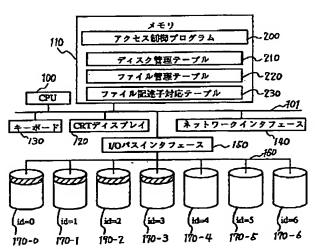
ャート

【符号の説明】

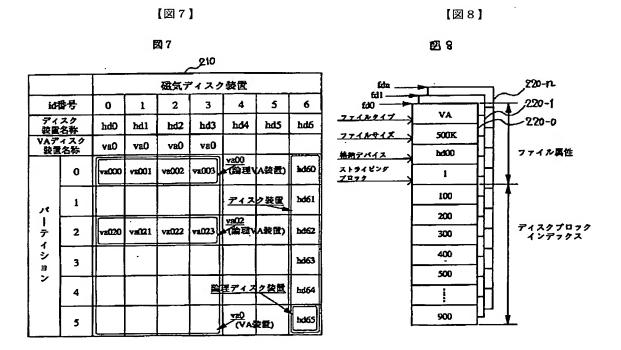
10…ファイル、10-0~10-9…ファイルを構成 するデータブロック、20-0~20-3…磁気ディス ク装置の内部キャッシュメモリ、100…CPU、10 1…共通データバス、110…メモリ、120…CRT ディスプレイ、130…キーボード、140…ネットワ ークインタフェース、150、151、152、153 … I / Oバスインタフェース、160、161、16 10 2、163… I / Oバス、170-0~170-6…磁 気ディスク装置、171-0~171-6…磁気ディス ク装置、172-0~172-6…磁気ディスク装置、 173-0~173-6…磁気ディスク装置、180-0~180-7…ディスコネクト/リコネクト手段、1 81-7、182-7、183-7…ディスコネクト/ リコネクト手段、190…ワークステーション、191 …LAN、200…アクセス制御プログラム、210… ディスク管理テーブル、220…ファイル管理テーブ ル、230…ファイル記述子対応テーブル、300、3 20 00-0~300-6…アレイディスク装置、310… FIFO0, 311...FIFO1, 312...FIFO 2、313…FIFO3、320…内部バス、330… バッファ、340…SCSIバスインタフェース、40 0…ホストCPU装置。

【図6】

图6

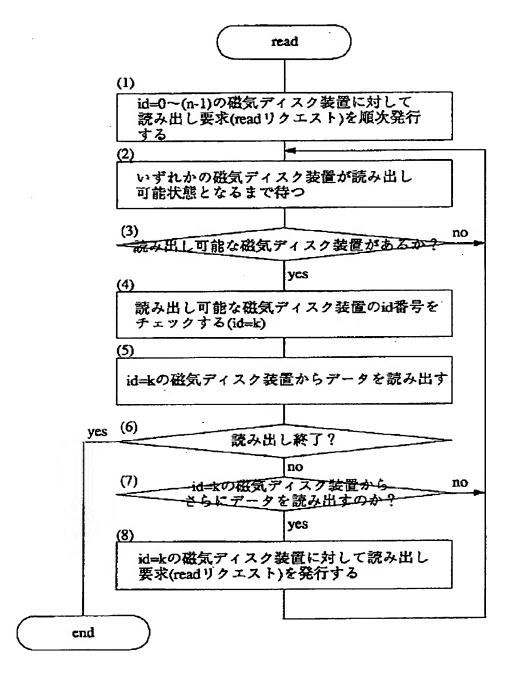


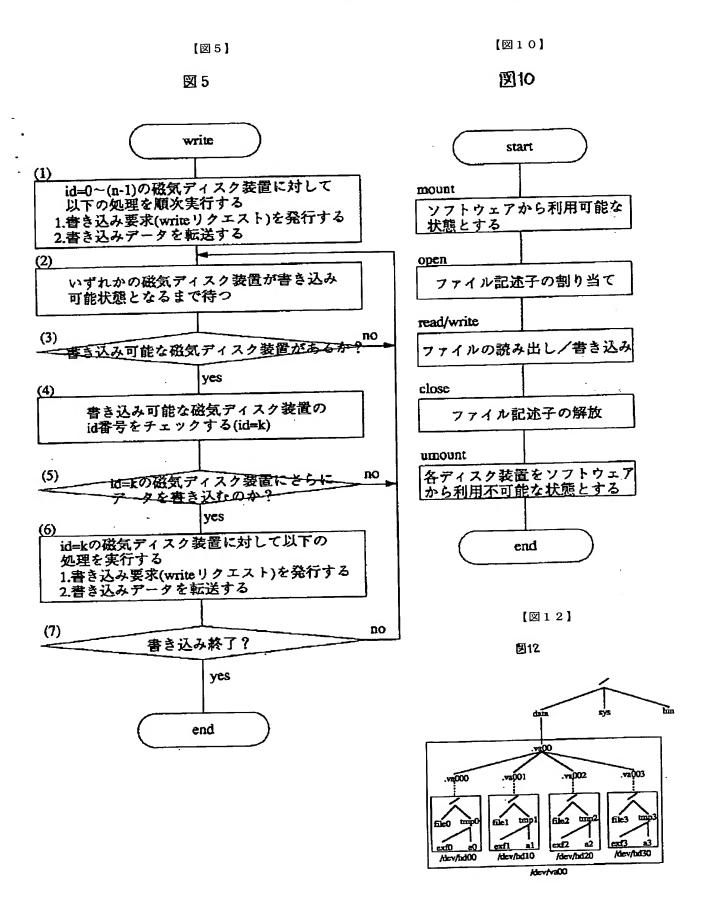
【図1】 【図4】 图1 図4 110 IAN 140 × 7+7-0 1×97-2 起動 T4 起動 起動 (1) **T4** T4 T4 なべ ワーク CPU 101 キーポード 150 1/0パス ディスプレイ id=0 -180-7 160 -TIHGF BDCBA T4 **T**4 T4 70 **T4** (2) po-1 po-8 10-7 10-6 po-5 po-4 po-3 po-2 po-1 po-0 180-0 I/O 170-0 - A E id=0 180-1 T1 -B F ---id=0 id=1 70-2 **←** C G id=2 180-3 70-3 **→** D H ···· □ 音き込み要求 TI:磁気ディスク装置のソフトウエアオーパヘッド id=3 180-4 T2:シーク時間+回転待ち時間 T3:内部キャッシュメモリからアィスク媒体へのデータ 転送時間 アータ転送 id=4 D ディスク媒体 アクセス 180-5 T4:ホストCPUから磁気ディスク装置へのデータ転送時間 (内部キャッシュメモリへの書き込み) 570-5 id=5 180-6 170-6 id=6

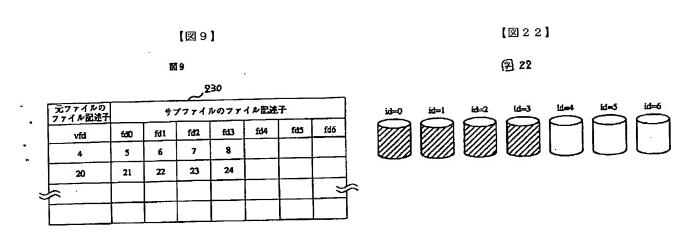


【図3】

図3

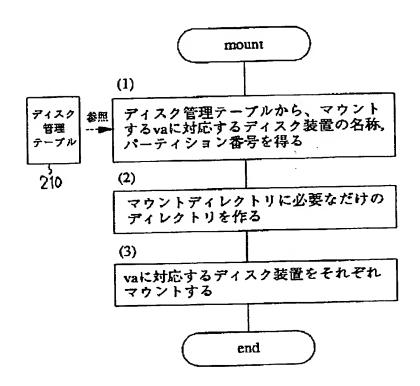






【図11】

图11

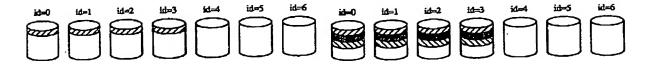


【図24】

【図26】

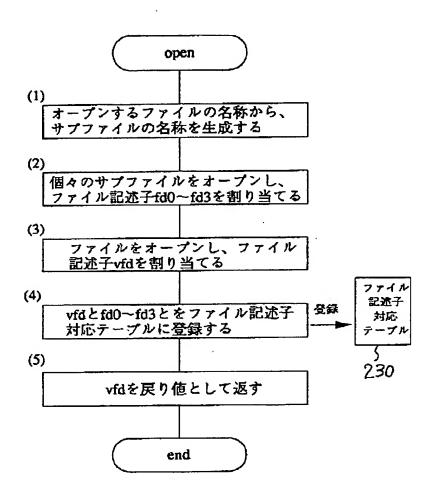
里 24

团 26



【図13】

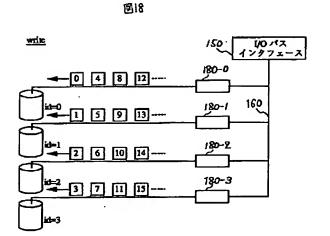
图 13

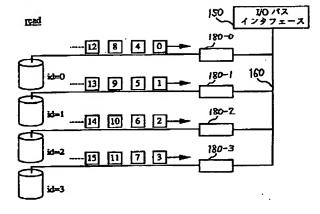


【図18】

【図19】

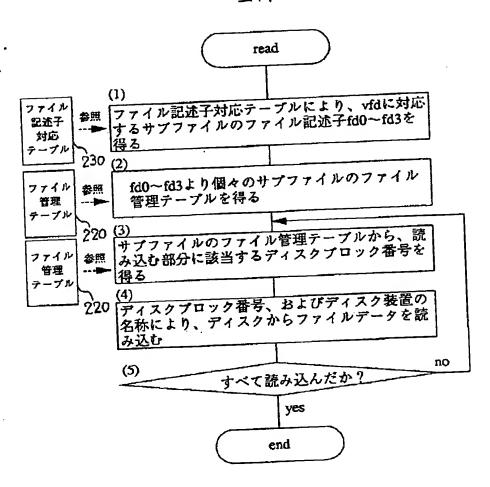
图19





【図14】

図14

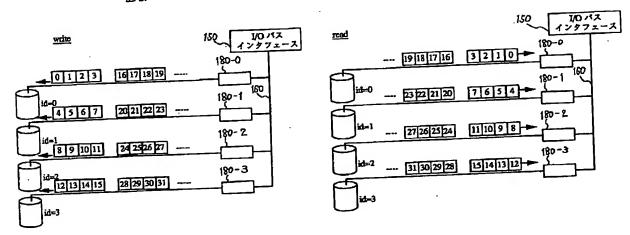


【図20】

【図21】

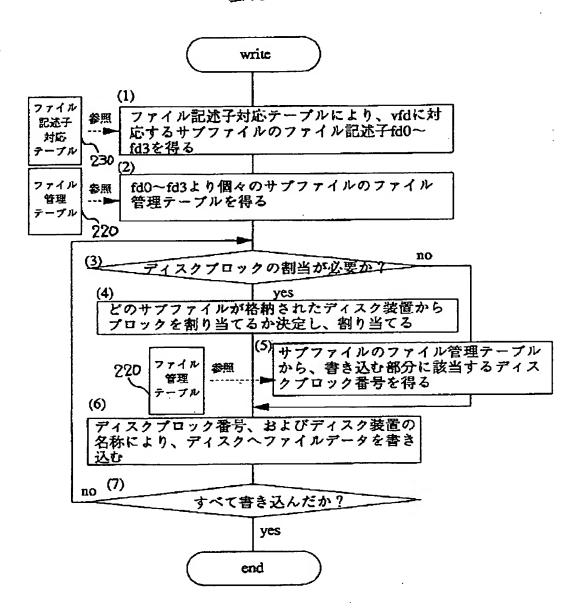
图20

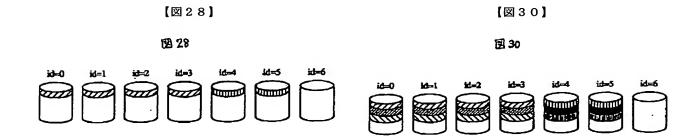
图21

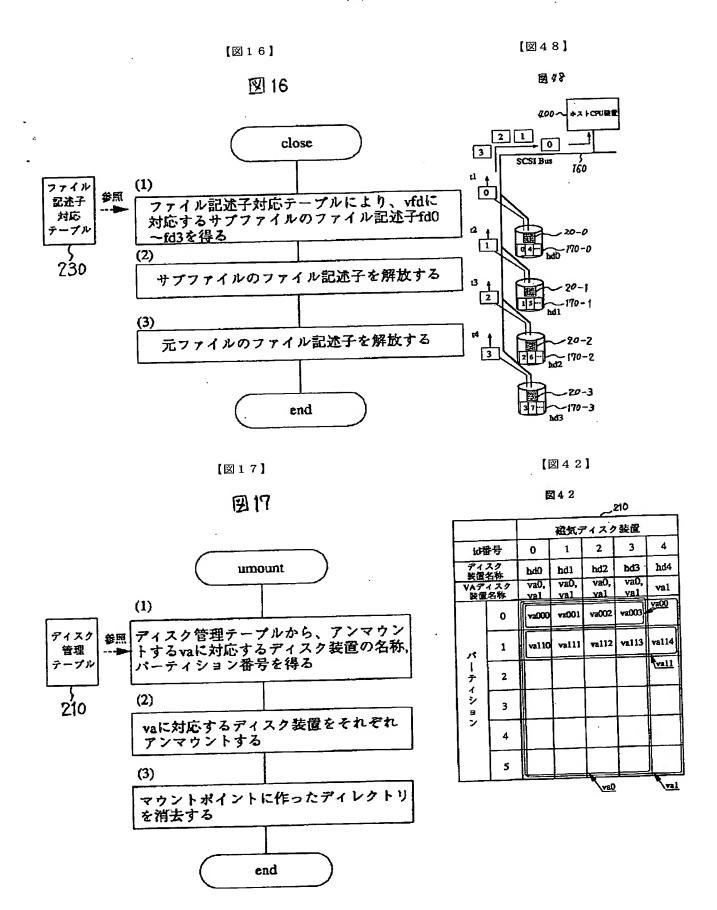


【図15】

図15







【図23】

図23

_

	المختر المحتاد									
			磁気ディスク装置							
id	id番号		1	2	3	4	5	6		
	ディスク 装置名称		hd1	hd2	hd3	hd4	hd5	hd6		
	VAディスク 装置名称		vaO	va0	va0					
	0	v2000	va001	væ002	₩2003	<u>va00</u>				
74	1.	vz000	vz001	va002	va003					
ーティ	2	va000	vzi001	va002	va003					
ーティション	3	va000	va001	va002	va003					
>	4	v a000	va001	v=002	vz003					
	5	vz000	va001	va002	va003	V#O				

【図25】

图25

						210				
			磁気ディスク装置							
idi	id番号		1	2	3	4	5	6		
ディ 装置		hd0	hdl	hd2	hd3	hd4	hd5	hd6		
	VAディスク 装置名称		va0	vaO	va0					
	0	va:000	va0 01	vz:002	v#003	<u>∨200</u>				
ρŧ	1									
ーティション	2									
ショ	3									
ン	4							-		
	5					ya0				

【図27】

図27

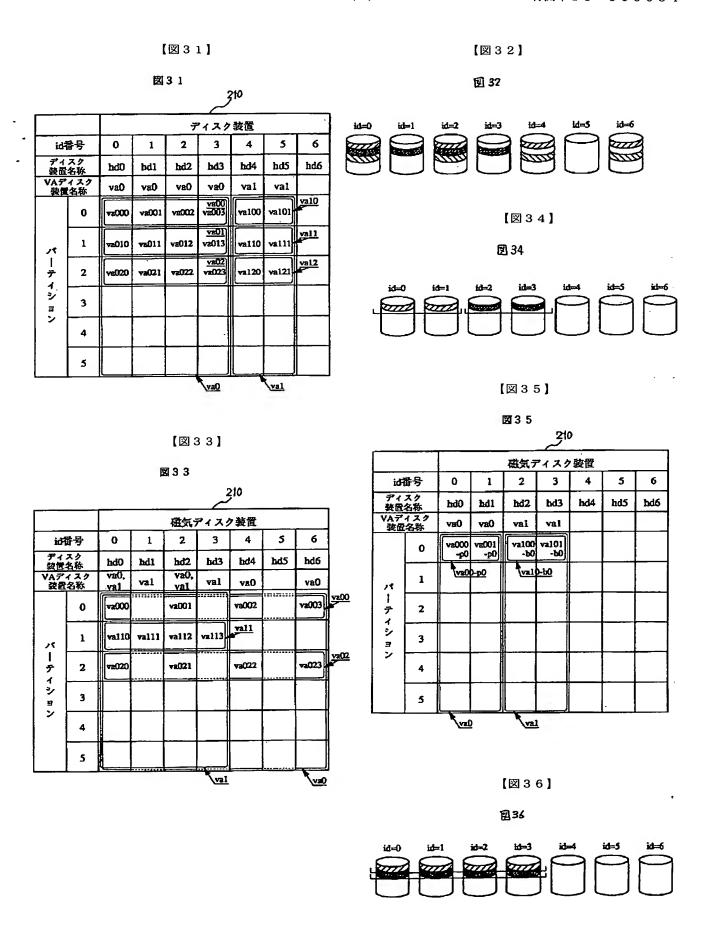
210

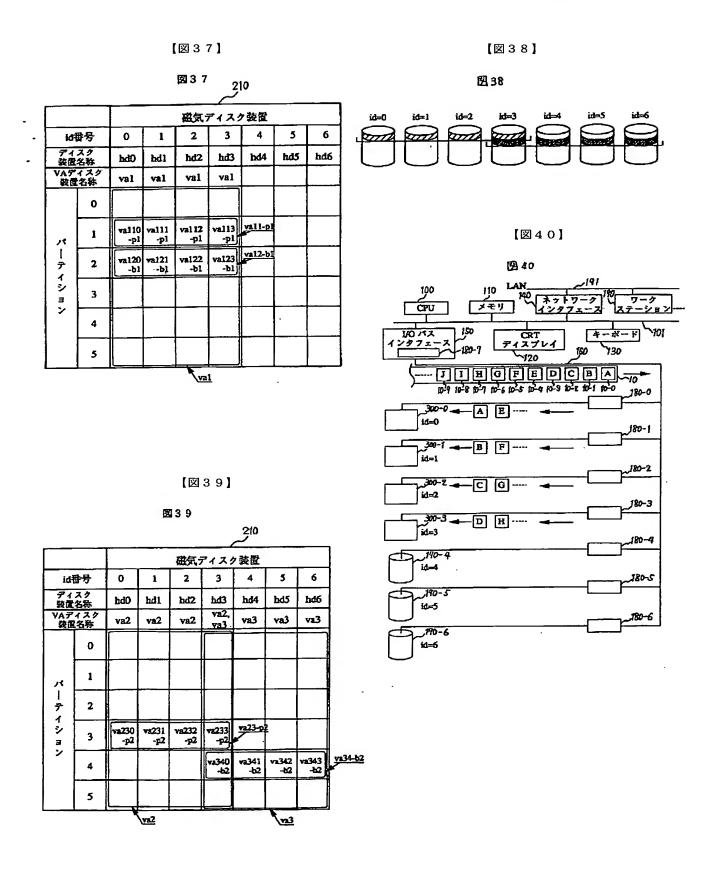
						<u> </u>			
		磁気ディスク装置							
idi	野	0	1	2	3	4	5	6	
ディ		hd0	hdl	hd2	hd3	hd4	hd5	hd6	
	イスク 名称	v æ0	va0	va0	va0				
	0	VE000	vx001	væ002	V2003	<u>va00</u>		•	
ρŧ	1	va010	v#011	va012	væ013	<u>va01</u>			
ーティショ	2	v2020	vz021	vz022	va023	<u>va02</u>	•		
マショ	3		•						
ン	4								
	5					¥ <u>0</u>			

【図29】

図29

						210		
				磁気	アイスク	・装置		
fbi	id番号		1	2	3	4	5	6
ディ: 装置:	スク 名称	hd0	bd1	bd2	hd3	hd4	hd5	hd6
VAデ 装置	ィスク 名称	va0	va0	va0	va0	val	val	
	0	va000	va001	va002	va003	val00	va101	<u>va10</u>
_K	. 1				<u>22200</u>			
ティ	2							
ーティション	3							
>	4							
	5							
					VZQ		VAL	





. 1))

MOパス ンタフェー

I/O bus3

113-0

, id=0

id=1 173-2

id=2

id=3

14-4

id=5

5 113-3

5 173-4

-5 m-1

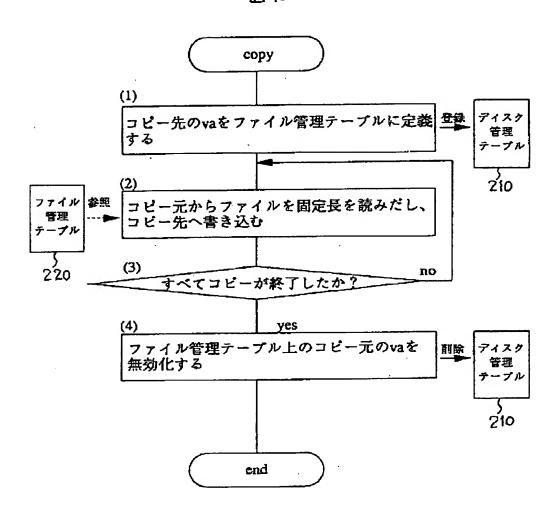
183-7

163

【図41】 【図44】 图41 图44 310 110 磁気ディスク装置 id番号 0 2 3 4 6 1 101 ディスク 設置名称 キーボード ad2 ad3 hdO hd1 hd2 adO ad1 136 VAディスク 装置名称 150 1/0 / 7 1 / 9 7 x vaO va0 vaO va0 va2 ¥200 va002 va003 AS000 v2001 va01-p0 182-7 va211 va21-p1 væ010 va210 va013 va011 va012 I/O bas2 I/O bas0 1/O bas1 160 161 -p0 -p0 -p0 -p0 -pl > 171-0 5 172-0 ーティシ va22-b1 ve022 va023 -p0 v±020 -p0 va221 va021 va220 2 -p0 -b1 -ы id=0 id=0 -p0 id=0 va02-60 170-1 172-1 171-1 3 3 id=1 id=1 id=1 4 772-2 <u> 1711-2</u> id=2 id=2 id=2 5 171-3 P72-3 170-3 <u>va2</u> id=3 id=3 5 172-4 171-4 id=4 id=4 5 170-5 id=5 id=5 【図46】 5771-6 id=6 id=6 图 46 サストCFU装置 160 3 3 2 10 ~340 371 300

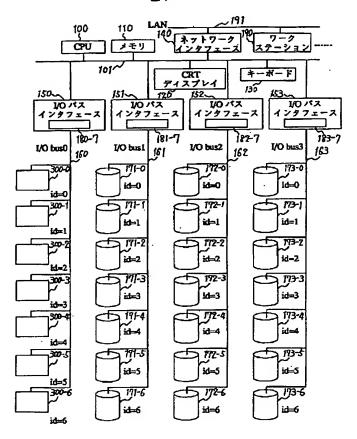
【図43】

图43



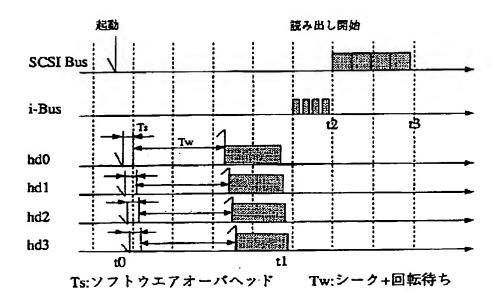
【図45】

四45



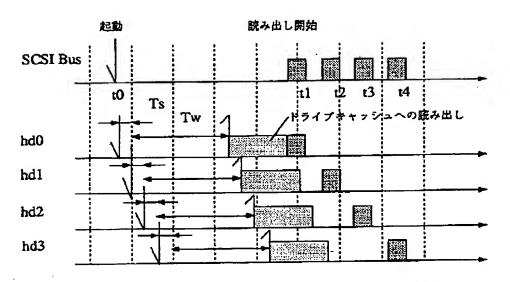
【図47】

图 47



【図49】

图 49



Ts:ソフトウエアオーバヘッド

Tw:シーク+回転待ち

フロントページの続き

(72)発明者 加藤 寛次

神奈川県川崎市幸区鹿島田890番地株式会 社日立製作所システム開発本部内 (72)発明者 鈴木 広義

神奈川県横浜市戸塚区戸塚町5030番地 株 式会社日立製作所ソフトウェア事業部内

(72) 発明者 牧 敏行

神奈川県秦野市堀山下1番地 日立コンピ ュータエンジニアリング株式会社内

This Page is Inserted by IFW Indexing and Scanning Operations and is not part of the Official Record

BEST AVAILABLE IMAGES

Defective images within this document are accurate representations of the original documents submitted by the applicant.

Defects in the images include but are not limited to the items checked:
BLACK BORDERS
IMAGE CUT OFF AT TOP, BOTTOM OR SIDES
☐ FADED TEXT OR DRAWING
☐ BLURRED OR ILLEGIBLE TEXT OR DRAWING
☐ SKEWED/SLANTED IMAGES
☐ COLOR OR BLACK AND WHITE PHOTOGRAPHS
☐ GRAY SCALE DOCUMENTS
LINES OR MARKS ON ORIGINAL DOCUMENT
☐ REFERENCE(S) OR EXHIBIT(S) SUBMITTED ARE POOR QUALITY
☐ OTHER:

IMAGES ARE BEST AVAILABLE COPY.

As rescanning these documents will not correct the image problems checked, please do not report these problems to the IFW Image Problem Mailbox.